

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky

BAKALÁŘSKÁ PRÁCE

2018

Eva Kotalová

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

**Analýza genetických algoritmů pro optimalizaci
multiregionální soft segmentace v aplikaci na medicínská
obrazová data**

**An Analysis of the Genetic Algorithms for the
Multiregional Soft Segmentation Optimization in
Application on Medical Image Data**

Zadání bakalářské práce

Student: **Eva Kotalová**
Studijní program: B2649 Elektrotechnika
Studijní obor: 3901R039 Biomedicínský technik
Téma: **Analýza genetických algoritmů pro optimalizaci multiregionální soft
segmentace v aplikaci na medicínská obrazová data**
**An Analysis of the Genetic Algorithms for the Multiregional Soft
Segmentation Optimization in Application on Medical Image Data**

Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování obecných principů segmentace obrazu.
2. Nastudování základních principů genetických algoritmů, které jsou aplikovatelné v oblasti segmentace obrazu.
3. Rešerše regionálních metod v kontextu zpracování medicínských obrazových dat.
4. Analýza obrazových dat z IR kamery, reflektujících intoxikaci alkoholem.
5. Definice obrazových příznaků, reflektujících dynamickou intoxikaci alkoholem.
6. Možnosti předzpracování IR obrazových dat.
7. Design a realizace multiregionálního segmentačního modelu, řízeného genetickým algoritmem pro extrakci faciálních oblastí, které spolehlivě reflektují dynamiku intoxikace.
8. Testování navrženého řešení na reálných IR datech.
9. Extrakce příznaků a hodnocení časové dynamiky intoxikace alkoholem na základě navrženého segmentačního modelu.

Seznam doporučené odborné literatury:

- [1] DIAKIDES, M., J. D. BRONZINO a D. R. PETERSON. *Medical infrared imaging: principles and practices*. Boca Raton, FL: CRC Press/Taylor & Francis, 2013. ISBN 978-1439872499.
- [2] VOLNER, M. AND K. P. MÖLLMANN. *Infrared thermal imaging: fundamentals, research and applications*. Weinheim: Wiley-VCH, 2010. ISBN 978-3527407170.
- [3] MITCHELL, Melanie. *Introduction to genetic algorithms*. Massachusetts: MIT Press, 1997. ISBN 978-0262133166.
- [4] PARKER, James R. *Algorithms for image processing and computer vision*. New York: Wiley Computer Pub., c1997. ISBN 0471140562.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Jan Kubiček**

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.



.....
Eva Kotalová

Datum odevzdání bakalářské práce: 30. 4. 2018

V Ostravě

dne: 30. 4. 2018

Poděkování

Na tomto místě bych ráda poděkovala svému vedoucímu práce panu Ing. Janu Kubíčkovi, Ph.D. za cenné rady a připomínky k vypracování této práce a veškerý čas, který mi věnoval. V neposlední řadě bych chtěla poděkovat celé mé rodině a přátelům za podporu při studiu.

Abstrakt

Tato bakalářská práce se zabývá analyzováním genetických algoritmů pro optimalizování multiregionálních soft segmentací v aplikacích na medicínská obrazová data. Konkrétním záměrem aplikace segmentační metody je analýza a modelování faciální teplotní distribuce z IR obrazových dat v průběhu intoxikace alkoholem. Předpokládaným záměrem této analýzy je matematický model, umožňující dynamické sledování postupné intoxikace alkoholem na základě dynamiky teplotní distribuce. V teoretické části práce jsou popsány metody pro zjišťování intoxikace alkoholem pomocí IR obrazu. Dále je uvedena aktivita krve v obličeji po intoxikaci alkoholem a vysvětlení genetických algoritmů. V praktické části práce je na IR obrazech od různých probandů aplikován genetický algoritmus K-means řízený ABC algoritmem, který extrahuje dané oblasti zájmu. Důležitou součástí analýzy je testování parametrů ABC genetického algoritmu s cílem dosažení optimalizovaného modelu teplotní distribuce.

Klíčová slova:

Alkohol, IR data, medicínská obrazová data, intoxikace, genetický algoritmus, K-means, ABC optimalizace

Abstract

This bachelor thesis deals with analysis of genetic algorithms for optimization of multiregional soft segmentations in medical image data applications. The specific purpose of segmentation method application is to analyze and model facial temperature distribution from IR image data during alcohol intoxication. The assumed intent of this analysis is a mathematical model allowing dynamic monitoring of gradual alcohol intoxication based on the temperature distribution dynamics. The theoretical part of the thesis describes methods for detection of alcohol intoxication by IR image. In addition, the activity of blood in the face after alcohol intoxication and explanation of genetic algorithms. In the practical part of the thesis, the K-means algorithm is controlled by an ABC algorithm that extracts the area of interest from the various probands. An important part of the analysis is the testing of ABC genetic algorithm parameters in order to achieve an optimized temperature distribution model.

Key words

Alcohol, IR data, medical image data, intoxication, genetic algorithm, K-means, ABC algorithm

Obsah

Seznam použitých symbolů a zkratk	10
Seznam obrázků	11
Seznam tabulek	12
Úvod	14
1 Přehled recentních metod pro detekci a klasifikaci intoxikaci alkoholem	15
1.1 Intoxikované osoby z IR obrazových záznamů	15
1.2 Definice alkoholu	15
1.3 Odhad intoxikace alkoholem z IR obrazů	17
1.4 IR Dataset	17
1.5 Rešerše metod detekce intoxikace alkoholem z IR obrazů	19
1.5.1 Aktivita krve v obličeji u osob intoxikovaných alkoholem	23
2 Současné metody segmentace obrazu v lékařství	33
2.1 Definice obrazu	33
2.2 Rozměrnost (Dimensionalita)	33
2.3 Intenzita nehomogenity	34
2.4 Metody	34
2.4.1 Prahování (Thresholding)	35
2.4.2 Zvětšování oblasti	35
2.4.3 Klasifikátory	35
2.4.4 Klastrování	36
2.4.5 Markov Random Field model	36
2.4.6 Umělé neuronové sítě	36
2.4.7 Deformovatelné modely	36
2.4.8 Atlasově řízené přístupy	36
2.4.9 Ostatní metody	37
3 Genetické algoritmy	38
3.1 Princip fungování genetických algoritmů	38
3.1.1 Návrh struktury	38
3.1.2 Inicializace	39
3.1.3 Ohodnocení	39
3.1.4 Selektce	40
3.1.5 Křížení	40
3.1.6 Mutace	41

3.1.7	Reprodukce	41
3.2	Využití genetických algoritmů	41
3.3	Výhody genetických algoritmů	41
4	Analýza IR záznamů	43
5	Předzpracování IR faciálních obrazů	47
5.1	Dekompozice IR RGB modelu.....	47
5.2	Extrakce oblasti zájmu	48
6	Návrh segmentačního algoritmu	49
6.1	Algoritmus K-means	49
6.2	Optimalizace ABC algoritmem	49
7	Průběh testování	52
8	Binární model IR teplotní distribuce	63
9	Závěr	66
10	Použitá literatura	67
Přílohy.....		71
Příloha na CD		71

Seznam použitých symbolů a zkratek

ABC	Artificial Bee Colony
ANN	Umělé neuronové sítě
BAC	Obsah alkoholu v krvi
BMI	Body mass index
BPNN	Back-Propagation trained Neural Network
CT	Výpočetní (počítačová) tomografie
DCT	Diskrétní kosinová transformace
DWT	Diskrétní vlnová transformace
D_p	Vzdálenost pixelu od těžiště
EB	Pracující včely
fit_i	Fitness hodnota i-tého řešení
GA	Genetický algoritmus
IR	Infračervený
L_v	Limit výběru
LDA	Lineární diskriminační analýza
MRF	Markov Random Field model
MRI	Magnetická rezonance
M_Δ	M_{delta}
M_d	$M_{\text{intoxikovaný alkoholem}}$
M_s	$M_{\text{střízlivý}}$
NIR	Blízké infračervené spektrum
OB	Vyčkávací včely
PCA	Principal Components Analysis
RTG	Rentgenové záření
RGB	červená-zelená-modrá
S	Celková populace
SB	Skauti
SN	Velikost populace
SVM	Support Vector Machine
$ \nabla u $	Modul gradientu

Seznam obrázků

Obrázek 1: Alkohol tester CA 20FL	16
Obrázek 2: Alkohol tester - DA 7000 ^[2]	16
Obrázek 3: Spektrofotometr 6850 ^[3]	17
Obrázek 4: Příklad obličejového thermogramu v monochromatickém formátu	18
Obrázek 5: Nastavení bodů na obličejí.....	19
Obrázek 6: Projekce podmnožiny dat ve dvou hlavních rozměrech	20
Obrázek 7: Rozdíl mezi střízlivými a intoxikovanými tepelnými změnami	21
Obrázek 8: Oblasti zájmu teplotních rozdílů.....	22
Obrázek 9: Příklad prostorového thermogramu	23
Obrázek 10: Thermogram po anizotropní difuzi.....	23
Obrázek 11: Thermogram po transformaci Top-Hat.....	24
Obrázek 12: Segmentace oka mezi duhovkou a bělímou.....	25
Obrázek 13: Konvergence barevných matic s oblastmi 3x3	26
Obrázek 14: Konvergence barevných matic s oblastmi 7x7	27
Obrázek 15: Výsledky získané u 3x3 oblasti	27
Obrázek 16: Výsledky získané u 7x7 oblasti	27
Obrázek 17: Čelní část vybraná pro analýzu NN	28
Obrázek 18: Zastoupení 2-úrovňového 2D DWT	30
Obrázek 19: Přesnost rozlišení SVM podle v	31
Obrázek 20: Ilustrace vlivu efektu s částečnými účinky, (a) ideální obraz, (b) získaný obraz	34
Obrázek 21: Metody prostorových prostorů a zvětšování oblasti, (a) histogram zobrazující tři zjevné třídy, (b) 2D funkční prostor, (c) příklad zvětšování oblasti	35
Obrázek 22: Náhodná generace.....	39
Obrázek 23: Fitness jedinců	39
Obrázek 24: Výpočet pravděpodobnostních hodnot pro ruletu.....	40
Obrázek 25: Graf vypočtené pravděpodobnosti pro ruletu	40
Obrázek 26: Schéma křížení	40
Obrázek 27: Závislost pulsu na množství alkoholu v krvi	44
Obrázek 28: Závislost systolického tlaku na množství alkoholu v krvi	44
Obrázek 29: Závislost diastolického tlaku na množství alkoholu v krvi.....	45
Obrázek 30: Termografické zobrazení v originálním formátu: a ₁ , bez intoxikace, a ₂ , po 200 ml alkoholu u probanda č.1; b ₁ , bez intoxikace, b ₂ , po 200 ml alkoholu u probanda č.2; c ₁ , bez intoxikace, c ₂ , po 200 ml alkoholu u probanda č.3.....	46
Obrázek 31: Termografické zobrazení v monochromatickém formátu: a ₁ , bez intoxikace, a ₂ , po 200 ml alkoholu u probanda č.1; b ₁ , bez intoxikace, b ₂ , po 200 ml alkoholu u probanda č.2; c ₁ , bez intoxikace, c ₂ , po 200 ml alkoholu u probanda č.3	47
Obrázek 32: Rozložení monochromatického zobrazení na RGB vrstvu: a ₁ , bez intoxikace, a ₂ , po 200 ml alkoholu u probanda č.1; b ₁ , bez intoxikace, b ₂ , po 200 ml alkoholu u probanda č.2; c ₁ , bez intoxikace, c ₂ , po 200 ml alkoholu u probanda č.3	48
Obrázek 33: Vybraná část obličejí (čelo, nos): a ₁ , bez intoxikace, a ₂ , po 200 ml alkoholu u probanda č.1; b ₁ , bez intoxikace, b ₂ , po 200 ml alkoholu u probanda č.2; c ₁ , bez intoxikace, c ₂ , po 200 ml alkoholu u probanda č.3	48
Obrázek 34: Demonstrace algoritmu.....	49
Obrázek 35: Vývojový diagram ABC algoritmu	50
Obrázek 36: Extrahovány oblasti zájmu (nos) po segmentaci K-means řízeným ABC algoritmem při nastavení 8 shluků, velikosti populace 100, 70 a 120, generace 100, 90 a 60	53

Obrázek 37: Extrahovány oblasti zájmu (čelo) po segmentaci K-means řízeným ABC algoritmem při nastavení 8 shluků, velikosti populace 100, 70 a 120, generace 100, 90 a 60	54
Obrázek 38: Graf fitness hodnot – nejlepší hodnota fitness: 1,45445 a střední hodnota fitness: 1,82048	55
Obrázek 39: Graf fitness hodnot – nejlepší hodnota fitness: 1,54123 a střední hodnota fitness: 1,55479	55
Obrázek 40: Graf fitness hodnot – nejlepší hodnota fitness: 1,14543 a střední hodnota fitness: 1,53675	56
Obrázek 41: Graf fitness hodnot – nejlepší hodnota fitness: 1,47337 a střední hodnota fitness: 5,20654	56
Obrázek 42: Graf fitness hodnot – nejlepší hodnota fitness: 0,881234 a střední hodnota fitness: 1,90901	57
Obrázek 43: Graf fitness hodnot – nejlepší hodnota fitness: 0,637925 a střední hodnota fitness: 0,933263	57
Obrázek 44: Extrahovány oblasti zájmu (nos) po segmentaci K-means řízeným ABC algoritmem při nastavení 3 shluků, velikosti populace 50, 100 a 50, generace 80, 100 a 100	59
Obrázek 45: Extrahovány oblasti zájmu (čelo) po segmentaci K-means řízeným ABC algoritmem při nastavení 3 shluků, velikosti populace 50, 100 a 50, generace 80, 100 a 100	60
Obrázek 46: Extrahované části (nos) u tří probandů při nastavených 13-ti shluků, velikost populace 200,100 a 50, generace 150, 100 a 100	62
Obrázek 47: Extrahované části (čelo) u tří probandů při nastavených 13-ti shluků, velikost populace 200,100 a 50, generace 150, 100 a 100	62
Obrázek 48: Binární model teplotní distribuce extrahované části (nos) u prvního probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	63
Obrázek 49: Binární model teplotní distribuce extrahované části (čelo) u prvního probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	63
Obrázek 50: Binární model teplotní distribuce extrahované části (nos) u druhého probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	64
Obrázek 51: Binární model teplotní distribuce extrahované části (čelo) u druhého probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	64
Obrázek 52: Binární model teplotní distribuce extrahované části (nos) u třetího probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	65
Obrázek 53: Binární model teplotní distribuce extrahované části (čelo) u třetího probanda: a) bez intoxikace, b) 40ml množství alkoholu, c) 80ml množství alkoholu, d) 120ml množství alkoholu, e) 160ml množství alkoholu, f) 200ml množství alkoholu.....	65

Seznam tabulek

Tabulka 1: Vlastní hodnoty os získaných pomocí lineární diskriminační analýzy (LDA)	20
Tabulka 2: Průměrná míra úspěšnosti pro 5 testovaných subjektů s příslušnou oblastí.....	28
Tabulka 3: Průměrná míra úspěšnosti pro všechny testované subjekty s pěti různými sítěmi.....	28
Tabulka 4: Průměrná míra úspěšnosti pro všechny testované subjekty s pěti různými sítěmi zaměřenými na čelo.....	29

Tabulka 5: Záznamy 5-ti náhodně vybraných probandů.....	43
Tabulka 6: Výpočetní čas při nastavení počtu shluků 8, velikost populace 100 a generace 100	52
Tabulka 7: Výpočetní čas při nastavení počtu shluků 8, velikost populace 70 a generace 90	52
Tabulka 8: Výpočetní čas při nastavení počtu shluků 8, velikost populace 120 a generace 60	53
Tabulka 9: Hodnoty fitness při nastavení počtu shluků 8, velikost populace 100 a generace 100	54
Tabulka 10: Výpočetní čas při nastavení počtu shluků 3, velikost populace 50 a generace 80	58
Tabulka 11: Výpočetní čas při nastavení počtu shluků 3, velikost populace 100 a generace 100	58
Tabulka 12: Výpočetní čas při nastavení počtu shluků 3, velikost populace 50 a generace 100	59
Tabulka 13: Hodnoty fitness při nastavení počtu shluků 3, velikost populace 50 a generace 80	60
Tabulka 14: Výpočetní čas při nastavení počtu shluků 13, velikost populace 200 a generace 150	60
Tabulka 15: Výpočetní čas při nastavení počtu shluků 13, velikost populace 100 a generace 100	61
Tabulka 16: Výpočetní čas při nastavení počtu shluků 13, velikost populace 50 a generace 100	61
Tabulka 17: Plocha binárního modelu extrahovaných částí u prvního probanda.....	64
Tabulka 18: Plocha binárního modelu extrahovaných částí u druhého probanda	65
Tabulka 19: Plocha binárního modelu extrahovaných částí u třetího probanda.....	65

Úvod

Alkohol (ethanol), je považován za nejčastěji užívanou drogu na světě. Je známo, že alkohol a nemoci jím způsobené, výrazně přispívají k celkovému počtu hospitalizací a úmrtí. Proto je potřeba vyvinout metody, které dokáží přesně odhadnout míru intoxikace organismu a předvídat poškození tkání, které požívání alkoholu způsobí.

Tato bakalářská práce je zaměřena na vyhodnocení míry intoxikace alkoholem pomocí aplikování genetických algoritmů na IR data daných probandů, na části obličeje, které jsou intoxikací alkoholem nejvíce zasaženy.

V první části se nejprve analyzují data jako je např. systolický a diastolický tlak, puls a jak se mění tyto hodnoty s intoxikací alkoholem. Dále jsou zde uvedeny další znaky, jako např. věk, pohlaví, výška a váha daných probandů.

V druhé části je předzpracování IR záznamů nejprve na monochromatický formát a poté dekompozice IR na RGB modely. Dále se mohou extrahovat dané oblasti zájmu čelo a nos. Na tyto oblasti zájmu se navrhne segmentační algoritmus, který je K-means řízený ABC algoritmem.

Ve třetí části probíhá průběh testování, pomocí genetického algoritmu a ten nám zobrazí teplotní mapu dané extrahované části.

V poslední části bakalářské práce je zobrazen binární model teplotní distribuce extrahovaných částí.

Cílem práce je vyhodnotit jak se po intoxikaci alkoholem daná část obličeje (čelo, nos) zahřívá a jak se mění teplotní mapa na této extrahované části.

1 Přehled recentních metod pro detekci a klasifikaci intoxikaci alkoholem

1.1 Intoxikované osoby z IR obrazových záznamů

Detekce intoxikace alkoholem je v mnoha oblastech náročným úkolem. Existuje mnoho metod, které odhadují množství alkoholu. Vedle dobře známých metod, které využívají analýzu dechu, lze úroveň intoxikace alkoholem odhadnout také pomocí obrazové informace. Vzhledem k tomu, že konzumace alkoholu je spojena se změnou rozložení teploty, je termální IR vhodným způsobem pro bezkontaktní detekci a sledování intoxikace alkoholem. Hlavním problémem, kterému se musí čelit, je to, že některé studie osvětlují vývoj teplotní mapy ze střízlivého stavu do intoxikace, ale neumožňují prokázat rozdíl mezi střízlivostí a intoxikací bez termogramu střízlivé osoby. Nejslibnější metody pro detekci intoxikace alkoholem, jsou více holistické a využívají klasické statistické techniky, jako je lineární diskriminační analýza, ale také pokročilejší technologie, jako jsou neuronové sítě nebo podpůrné vektorové stroje.

1.2 Definice alkoholu

Alkohol, v tomto případě ethanol, je považován za nejčastěji užívanou drogu na světě. Je známo, že alkohol a nemoci jím způsobené, výrazně přispívají k celkovému počtu hospitalizací a úmrtí. Proto je potřeba vyvinout metody, které dokáží přesně odhadnout míru intoxikace organismu a předvídat poškození tkání, které požívání alkoholu způsobí. BAC (obsah alkoholu v krvi), je měření ethanolu, které odhadujeme z krevních a dechových testů. Výsledky těchto testů byly považovány za přesné ukazatele ^[1] při zjišťování, zda je osoba pod vlivem alkoholu nebo ne. Jedním z hlavních nevýhod těchto metod je to, že vyžadují přímý kontakt a souhlas vyšetřované osoby. Navíc nejsou vždy spolehlivé ^[2]. Výše uvedené skutečnosti představují důvody, proč bychom měli hledat různé ukazatele, které mohou indikovat intoxikaci alkoholem bezkontaktním způsobem. Za takový způsob lze považovat analýza obrazu.

Z chemického hlediska, je za intoxikaci alkoholem odpovědný ethanol (C_2H_6O). Ethanol se dostává do krve trávením a v organismu je odbouráván v játrech, jejichž hlavní funkcí je čistit krev. Jestliže je množství přijímaného ethanolu v těle větší než absorpční kapacita jater, ethanol se dostane do krevního oběhu, což má za následek změny organismu. Ethanol totiž ovlivňuje většinu našich orgánů, a to včetně mozku, což způsobuje nejviditelnější projevy intoxikace. ^[3, 4, 5]

Krátce po vstoupení alkoholu do krevního oběhu, prochází také plícemi, jelikož jsou součástí malého krevního oběhu, proto může být ethanol zjištěn také v dechu intoxikovaného. Koncentrace alkoholu v dechu, je přímo úměrná koncentraci alkoholu v krvi ($\times 2100$ při 294 K). Vzhledem k tomu, že přístup k dechu člověka je poměrně snadný, byla tato technika nejčastěji používaná k odhadu BAC prostřednictvím zařízení, které nazýváme alkohol tester. ^[6, 7]

Alkohol testery se vyrábějí ve třech typech:

- I.** Elektrochemické: Fuel cell (palivový článek), je to technologie založena na principu palivového článku. Fuel cell se nezahřívá (vyšší výdrž baterií) v průběhu zkoušky pouze tlakové čidlo kontroluje množství vdechnutého vzduchu a na konci zkoušky pumpa nasaje do článku přesný objem vzorku. Článek začne spalovat alkohol a vyrobí z něj elektrický proud. Podle množství vyrobeného proudu je určeno množství alkoholu v dechu. Fuel cell není ovlivněna žádnými cizími látkami ani silou dechu. Jednotlivé Fuel cell se mezi sebou liší objemem nasátého vzduchu, čím větší objem tím větší přesnost a také výdrž. Na obrázku 1 můžeme vidět jeden z typů elektrochemického alkohol testeru. ^[1]



Obrázek 1: Alkohol tester CA 20FL

- II.** Polovodičové: Polovodičové čidlo se zahřeje na teplotu kolem 300 °C, vdechnutý vzduch v průběhu zkoušky dopadne na čidlo, kde se mění elektrické napětí, v závislosti na množství alkoholu a jiných těkavých látek. Změna napětí je pak vyhodnocena a jako výsledek zobrazena hodnota na displeji. Tyto alkoholtestery jsou vhodné pro osobní použití, nebo např. do automobilu na dýchnutí před jízdou. Obrázek 2 znázorňuje jeden z typů polovodičového alkohol testeru.



Obrázek 2: Alkohol tester - DA 7000 ^[2]

- III.** Spektrofotometry: Pracují v blízkém infračerveném spektru (NIR), které jsou schopné podrobněji vysvětlit složení vydechaného vzduchu. Měří koncentraci rozpuštěné či rozptýlené látky na základě intenzity světla dané vlnové délky, které prošlo měřeným vzorkem, resp. které bylo měřenou látkou pohlceno. Tato metoda je velmi přesná a je používána na policejních stanicích (viz. obrázek 3). ^[18, 19]



Obrázek 3: Spektrofotometr 6850 ^[3]

1.3 Odhad intoxikace alkoholem z IR obrazů

Alkohol testery a krevní testy sice zajišťují převážně spolehlivé výsledky, ale patří mezi kontaktní metody, které lze provést pouze se souhlasem testovaného subjektu. Další nevýhodou je, že některé z těchto testů lze provádět pouze v klinických podmínkách.

Je známo, že intoxikace alkoholem způsobuje vazodilataci, proto požití většího množství alkoholu lze jednoduše poznat na tváři intoxikovaného. Je to následek toho, že žíly v obličeji jsou blízko pokožce. Krev má vyšší teplotu, než je teplota povrchu těla, proto po požití alkoholu teplota tváře roste a intoxikovaný člověk rudne, což odpovídá červenému spektru.

Z tohoto důvodu je infračervený snímek stanoven přibližně na $9,5\ \mu\text{m}$, což je hodnota pro získání relevantních dat. Pro toto nastavení existují i další důvody. 1) snímek je necitlivý na intenzitu světla, proto je měření prováděno v noci (nedostatek světla by mohl narušit analýzu viditelného spektra). 2) infračervená radiace těla je určována emisivitou povrchu a druhem lidské kůže. Tyto údaje se pak pohybují mezi 0,98 a 0,99 (% kolik může lidské tělo vyzařovat v případě, že by bylo tělo úplně černé).

Změnu teploty po intoxikaci alkoholem lze nejviditelněji rozeznat na tváři. Důležité je zjistit, které části obličeje tuto změnu nejvíce reflektují.

Pomocí IR obrazů budeme moci určit, zda je osoba intoxikovaná nebo střízlivá. Otázkou je, zda tato metoda bude mít potenciál vyvinout prediktivní model, který bude odhadovat různé úrovně alkoholu v krvi (BAC).

1.4 IR Dataset

Dokumenty prezentované v tomto přehledu popisují postupy, které jsou zaměřené nebo souvisejí s identifikací intoxikované osoby na základě termografické nahrávky. Všechny užívají stejná data pro nastavení této analýzy.

Velikost reprodukovatelnosti jakéhokoliv segmentu silně záleží na charakteristice obrazu (kontrast, rozlišení atd.).

Analýza může jít několika směry, nejjednodušší způsob je odpověď osoby, zda je intoxikovaná nebo střízlivá, ale více komplexní by mohlo být klasifikování množství alkoholu. Později budeme potřebovat přístup k výsledkům BAC spojené s termogramy, například přes nástroje k dýchání (měření fouknutím). Další fyziologické údaje jako jsou věk, váha a BMI jsou také důležité. Další problém může být opakované měření, kde můžeme mít stejné nebo i jiné výsledky v závislosti

na teplotě. Dále také inklinace jednotlivých druhů alkoholu (víno, pivo, pálenky...) může být důležitá. Bohužel ne všechny tyto informace jsou ale při analýzách uváděny.

Ve [4] a [6] pracovali autoři se snímky z 20 různými lidmi (12 mužů a 8 žen), pořízených kamerou Thermal Vision Micron/A10 vyrobenou FLIR systems Inc. Tato kamera snímá na vlnách v rozmezí 7,5 μm až 13 μm . Každá osoba vypila 330 ml piva, 4x po sobě v intervalu cca 20 minut. Jedno snímání bylo před prvním pivem, druhé po vypití všech čtyř. Všechny akvizice mají 50 obrázků, výsledkem bylo 250 snímků pro každou osobu. Teplota v místnosti se neměnila, stejně jako teplota servírovaného nápoje. Testované subjekty byli klidné, v normálním psychickém rozpoložení.

V [6] a [7] bylo pivo nahrazeno 120 ml červeného vína (13 % alc). Všechny 41 testovaných subjektů (31 mužů a 10 žen) vypilo 4 skleničky během jedné hodiny. 30 min po poslední skleničce někteří cítili, že jsou mírně intoxikováni, zbytek nepoznal rozdíl. Všichni testovaní byli v normálním psychickém rozpoložení.

V [8] byly snímky pořízeny kamerou ThermoVision A40, také vyrobenou FLIR systems Inc. Tato kamera snímá na vlnách od 8 μm do 14 μm . Pořízeno bylo 200 snímků mírně intoxikovaných testovaných osob, poté 200 snímků již intoxikovaných osob a 10 snímků 40 střízlivých osob. Celkem bylo pořízeno 800 snímků osob, jejichž stav se měnil z intoxikace do střízlivosti. Snímky byly pořízeny v rozlišení 60x80 px. Teplota vzduchu při focení byla regulována klimatizací na 24,3 °C. Ve všech těchto studiích byly výsledné thermogramy monochromatické, jako můžeme vidět na obrázku 4.



Obrázek 4: Příklad obličejového thermogramu v monochromatickém formátu


1.5 Rešerše metod detekce intoxikace alkoholem z IR obrazů

V [4] jsou zkoumány dvě nezávislé metody. Každá z nich je posuzována samostatně.

První metoda: Hodnoty pixelů

Vlastnosti extrakce

Na každém obličejí je přibližně 20 bodů, na kterých můžeme po požití alkoholu sledovat červené teplotní spektrum tváře, které se pak používá pro analýzu. Tyto body byly manuálně vybrány na každém obličejí podle obrázku 5.



Obrázek 5: Nastavení bodů na obličejí

Pixely byly převedeny do černobílé, hodnota každého pixelu je 1. Tato operace se prováděla jednou pro každý snímek, rozlišeného v 50 bodovém clusteru, v 20 dimenzionálním prostoru pro každý individuálně.

Clustery

Aby analýza byla relevantní, musí se zkontrolovat všech 50 bodů clusteru střízlivého a intoxikovaného probanda, tak aby byly snadno rozlišitelné (prvně se kontroluje snímek střízlivého probanda a poté intoxikovaného). Porovnávají se rozdíly mezi střízlivým a intoxikovaným s maximální standartní odchylkou těchto bodů (s clusterem a bez clusteru). Například vzdálenost mezi clustery je 5x větší než maximální rozptýlení. To znamená, že je velmi nepravděpodobné, že u osoby střízlivé a intoxikované alkoholem budou clustery zaměněny.

Výsledky jsou nejvěrohodnější, pokud se porovnává cluster první akvizice (střízlivý) a třetí akvizice (po dvou drincích). A následně je porovnávána třetí akvizice s pátou. Tato metoda může určit intoxikaci, ale ne přesnou úroveň intoxikace.

Prostor a dimenze


Clustery jsou rozdělitelné, proto byla vyzkoušena diskriminantní analýza na 8 lidech (16 clusterů) stejného pohlaví a váhy a vytvořilo se vizuálně přesvědčivé zobrazení.

Jen prvních pět bodů analýzy jsou zapsané v tabulce 1, kompozice (lineární kombinace) os zůstává neznámá, takže nemůžeme přesně určit, který z 20 bodů analýzy je nejvlivnější, což by bylo zajímavým výsledkem.

Tabulka 1: Vlastní hodnoty os získaných pomocí lineární diskriminační analýzy (LDA)

Pořadí	Vlastní hodnoty	Procento diskriminační síly	Kumulovaná diskriminující síla
1.	2,48	47	47
2.	1,22	23	70
3.	0,74	14	84
4.	0,33	6	90
5.	0,22	4	94

Později byla určena hranice pro „intoxikovaný“ ve dvou dimenzích, tedy byly použity první dvě hodnoty. Přidali se další informace o jedincích, aby se mohlo srovnat více informací. Výsledek tohoto srovnání je v grafu na obrázku 6.



Obrázek 6: Projekce podmnžiny dat ve dvou hlavních rozměrech

Hranice mezi střízlivým a intoxikovaným byla ručně určená, spojením středem bodů, které byly určeny střízlivou a intoxikovanou dvojicí. K vytvoření grafu nebyl použit žádný speciální algoritmus.

Použití prostoru k rozlišování

Po získání metody, která se zdála být schopná rozlišit mezi střízlivým a intoxikovaným, se byla použita vyřazovací metoda. Tato metoda se skládá z opakování výše uvedeného postupu. Celý postup byl opakován 8x. Celkem mělo být 8 testovaných skupin, testováno bylo nakonec pouze 7 clusterů, poslední, osmý, byl vyloučený a byl testován zvlášť. Tato metoda měla za cíl přiblížit se reálným životním situacím. Tyto data, ale nebyla použita pro určení výsledku.

Míra úspěšnosti tohoto postupu nebyla vždy vysoká, protože získaných dat nebyl dostatek, neobsahovaly všechny potřebné informace.

Byly hodnoceny rozdíly mezi 8 testovanými a vylučovací metodou vytvářeli pomocí kosinu a úhlů, prostor mezi příslušnými osami.

Průměrný rozdíl byl nalezen mezi body 15,26 ° na hlavních osách a 20,5 ° pro ostatní osy.

Druhá metoda: teplotní difference

V tomto druhém postupu bylo zaměřeno na teplotní rozdíly jednotlivých částí tváře vyvolané intoxikací alkoholem. Cílem bylo zjistit, zda některé odchylky teplotního rozdílu, mohou být charakteristické pro intoxikaci alkoholem.

Vlastnosti extrakce

Po normalizaci obrazů z hlediska stupnice a polohování, byly rozděleny v matici 8x5, o rozměrech 10x10 pixelů. Následně byla vypočtena průměrná hodnota pro každou oblast. To mělo za cíl získat 40-dimenčních polí V , kdy každá část pole odpovídala teplotě určité oblasti obličeje.

Následně byla pro každý snímek vypočtena matice 40x40 M . Rozdíly mezi jednotlivými oblastmi. M jsou vyjádřeny jako:


$$M_{i,j}=V_j-V_i \quad (1)$$

Pro každou osobu nyní lze porovnat matrice získané u střízlivého a intoxikovaného alkoholem člověka a do jiné matice jednoduše získané při operaci:

$$M_{\Delta} = M_d - M_s \quad (2)$$

M_{Δ} M_{delta}
 M_d $M_{intoxikovaný\ alkoholem}$
 M_s $M_{střízlivý}$


Výsledky



Obrázek 7: Rozdíl mezi střízlivými a intoxikovanými tepelnými změnami

Na obrázku 7 můžete vidět příklad matice. Nejjasnější body odpovídají dvojicím, ve kterých byl teplotní rozdíl největší.

Maximální hodnota je 29,7970 (hodnota pixelu, nikoliv teplota ve stupních) pro body na čele. Na Obrázek 8 lze vidět, že celkově byly nejvýznamnějšími ty body, které spojovaly některou oblast na čele, kde teplota klesala s jinou oblastí obličeje např. kolem úst a nosu (zde se teplota zvyšovala).



Obrázek 8: Oblasti zájmu teplotních rozdílů

Podrobně byly popsány výsledky získané měřením na čele a nose od šesti osob. Výsledky ukazují, že za normálních podmínek je nos chladnější než čelo, a postupně se začne zahřívat, zatímco se čelo ochlazuje. Lze říct, že nos má vyšší teplotu než čelo. Na druhou stranu, porovnáním výsledků získaných u párů čelo – nos u šesti subjektů vidíme, že v jednom případě (a údajně více na větším vzorku) teplota nosu zůstává stále nižší než teplota čela, což je problém, protože při detekci intoxikace tímto způsobem, je velmi nepravděpodobné, že bude k dispozici termogram střízlivé osoby, u které právě probíhá identifikace intoxikace. Lze říct, že nebude možné odhalit intoxikaci pouze na základě aktuálního termogramu. Dalším problémem je, že se přesně neví v kolika případech je teplota nosu ve střízlivém stavu nižší než teplota čela. I když toto platí pro všech šest prezentovaných subjektů. Výhodou zde popsaného postupu je, že nedojde k teplotnímu zkreslení celé tváře, jelikož bude analyzován pouze rozdíl mezi určitými částmi tváře.

Závěr

První navrhovaná metoda se zdála do určité míry funkční, ovšem není zcela spolehlivá. Jak jsme viděli, některé klastry zůstávají extrémně blízko k hranicím opilého prostoru. Aby se zlepšila stabilita metody, mohla by se zvýšit rozměrnost analýzy, ale byl by požadován algoritmus opilého prostoru, to je ovšem ve více než dvou rozměrech velice pracné.

Výběr jednoho pixelu jako vstupu může způsobit, že metoda bude velmi citlivá na šum, avšak průměrná hodnota z několika sousedících pixelů by tento problém snadno vyřešila. Hlavním problémem této metody je, že pracuje bez zásahu člověka. Aby se na každé tváři získaly přesně stejné body, bude zapotřebí velmi přesný systém k rozpoznávání obličeje.

Ve druhém postupu lze očekávat zajímavé výsledky. Můžeme vidět jasné zvýšení teploty nosu. To vede k významnému teplotnímu rozdílu mezi oblastmi čelistí a nosu. Ale jelikož střízlivý termogram by neměl být k dispozici pro identifikační opilsti, tento vývoj nebude znám.

Můžeme analyzovat pouze teplotní rozdíl a viděli jsme, že na šesti podnětech nebylo ani v jednom z nich významný. Zůstává zajímavou vlastností, ale není optimální. Na druhé straně by bylo mnohem snazší dosáhnout detekce nosu a čela přesněji než s 20 body první metody. Mohla by být také aplikována diskriminační analýza jako v prvním postupu, vzalo by se v úvahu více párů.

1.5.1 Aktivita krve v obličeji u osob intoxikovaných alkoholem

V [5] se k identifikaci opilosti využívalo analyzování cév v obličeji. Jak je vidět na obrázku 9, bez jakéhokoliv ošetření nejsou krevní obrazy na termogramu viditelné.



Obrázek 9: Příklad prostorového thermogramu

Aby to bylo zřejmé, byly na zpracování obrazu použity dvě po sobě jdoucí metody.

První krok: Anizotropní difuze

Vzhledem k tomu, že přínos krevních cév v obličeji v tepelné distribuci je velmi malý, pracuje se s velmi slabými signály, je důležité zlepšit poměr signál/šum. Anizotropní difuze je proces šíření energie každého pixelu obrazu na sousední pixely v takovém rozsahu, který je funkcí gradientu obrazu. Tím pádem správným výběrem funkce se podaří rozdělovat slabší a silnější hrany v menší nebo větší vzdálenosti. Vybraná funkce byla následující:

$$g(|\nabla u|^2) = \frac{1}{1 + \frac{|\nabla u|^2}{k^2}} \quad (3)$$

Kde $|\nabla u|$ je modul gradientu, jedná se o nastavitelný parametr. V tomto případě byl experimentálně nastaven na hodnotu 20. Tato funkce g vyhovuje výše zmíněným cílům, jelikož když se gradient zvýší, funkce se přiblíží nule. Funkce se také blíží k nule v případě, že je gradient malý. Výsledek aplikace anizotropní difuze je vidět na obrázku 10.



Obrázek 10: Thermogram po anizotropní difuzi

Je zřejmé, že nejdůležitější hrany (obrys obličeje) byly ostré a pokožka byla vyhlazena (redukci šumu). Krevní cévy jsou pro nás ovšem stále neviditelné.

Druhý krok: Top-Hat Transformace

Po zlepšení kvality obrazu se pomocí techniky Transformace Top-Hat extrahovaly z obličeje krevní cévy. Jedná se o techniku extrakce vzoru, která je zaměřena na vyjímání detailů podle strukturovacího prvku tak, že provádí *otevřací* proceduru se strukturovacím prvkem a poté analyzuje rozdíl mezi původním a otevřeným obrazem.



Obrázek 11: Thermogram po transformaci Top-Hat

Na obrázku 11 vidíme, že extrakce byla velmi účinná. Pro dvacet testovaných subjektů platí, že výsledky byly vždy podobné. Hodnoty získané u intoxikovaných obličejů byly o 25 % lepší než hodnoty získané u střízlivých.

Závěr

Tato studie ukazuje, že existuje významný a stabilní nárůst koncentrace krevních cév v obličeji. Při této metodě lze pomocí dvou thermogramů téhož člověka rozlišovat, zda je osoba střízlivá nebo intoxikovaná.


Musíme ovšem předpokládat, že se koncentrace může mezi jednotlivci lišit, a to v závislosti na velikosti hlavy nebo kvalitě a tloušťce kůže.

Termografické snímání oka

V [6] autoři zkoumali dopad intoxikace alkoholem na teplotu oka. V oku očekávali, že by se sklera stala teplejší než duhovka, kvůli vyšší koncentraci hustotě cév.

Nejprve se snažili různými metodami o to, aby zvětšení bylo zřejmé pouhým okem. Proto byl pro 28 subjektů použit algoritmus k vyrovnaní histogramu. Jiné algoritmy, jako je např. funkce `imadjust()` z MATLABu, která řeší horní a spodní pásy histogramu podle daných prahových hodnot a pak roztahuje zbytek do původního rozsahu, nebo histogramová logaritmická transformace umožňující, aby to bylo zřejmé v 8 a více případech. U pěti subjektů nebylo zjištěno zvýšení teploty skeletu.

Pro obě dvě studie provedené a podrobně uvedené níže, se domníváme, že žádný z těchto algoritmů nebyl použit. V první analýze oddělily oko mezi duhovkou a sklerou (bělimu) do dvou elips, jak je znázorněno na obrázku 12.



Obrázek 12: Segmentace oka mezi duhovkou a bělimou

Jednotlivě se extrahovala průměrná hodnota pixelu obou oblastí a poté se vypočítá poměr mezi bělimou a duhovkou pro každý snímek.

Rozdíl mezi střízlivou a opilou skupinou se zdá být zřejmý, ale je zde uplatňován Student t-test, který potvrzuje, že skutečné výsledky obou skupin se liší s vysokou pravděpodobností (99,95%).

Porovnáním rozdílu mezi střízlivými a intoxikovanými hodnotami pro tutěž osobu bylo zjištěno, že mezi 41 subjekty, 36 prokázalo čistý nárůst koeficientu, 2 snížený a u 3 zůstal vyrovnaný.

Ve druhé analýze byly spojeny dvě elipsy, tak aby oko mohlo být považováno za celek. Cílem bylo ověřit, zda rozdíl mezi střízlivým a intoxikovaným byl značný. Poté se vypočítá rozptyl na množině všech pixelů obsažených v oku pro každý snímek.

Porovnáním rozdílu mezi střízlivými a intoxikovanými hodnotami pro tutěž osobu bylo zjištěno, že mezi 41 osobami, 37 vykazovalo čistý nárůst rozptylu, zatímco u 4 pokleslo. Z těchto 4 je důležité poznamenat, že ve třech případech selhal pokus o první analýzu. Jedním z možných vysvětlení je, že tito lidé pravidelně užívali alkohol.

Závěr

Pokud ani nárůst teploty není vždy patrný, identifikace výhradně na základě konečné teploty bude nepřesná. To bude také tento případ, protože při opakování měření bychom neměli mít přístup k termogramu neintoxikovaného probanda. V datech, které představují, se opilé a střízlivé shluky jasně překrývají, což znemožňuje prahování.

Navíc se tato metoda zdá být neúčinná u lidí kteří užívají alkohol pravidelně.

Klasifikace intoxikovaných osob pomocí neuronových sítí

V [7] autor využívá k rozhodnutí o tom, která část obličeje je k identifikaci intoxikace alkoholem nejlepší pro neuronové sítě. Neuronová síť může být chápána jako heuristický model, který se snaží reprezentovat složité vztahy mezi vlastnostmi prezentovanými jako vstup (každý vstup má mnoho vlastností, každá vlastnost je hodnota, která se přenáší na jeden vstupní neuron), provozováním postupných lineárních kombinací několika vrstev malých jednotek: neurony. Nejprve existuje množina dat obsahující očekávaný výstup pro každou hodnotu (zde například: intoxikovaný nebo střízlivý). Cílem je přizpůsobit koeficienty tak, že při prezentaci na některé nové údaje má +vysokou změnu v poskytování odpovídajícího výsledku.

Typ neuronové sítě, která je zde používána, je BPNN (Back-Propagation trained Neural Network), která je nejjednodušší a nejběžnější. Během výcviku vypočítáme pro každý daný vstup chybu mezi efektivním a očekávaným vstupem, který se nazývá „funkce chyb“ nebo „účelová funkce“. Výsledek tohoto výpočtu určí, jak mají být přizpůsobeny koeficienty neuronů, které nejvíce přispívají k výsledku.

Modifikace koeficientů neuronů se pak šíří zpět do různých vrstev, takže síť by měla při dalším měření lépe odpovídat očekávanému výsledku.


V tomto pokusu se zadají vlastnosti obrazu a zjistí se, zda se dá na základě neuronové sítě odvodit opilost osob. Měření se provede pro různé části obličeje, protože je známo, že pokud BPNN dává dobré výsledky v dané oblasti, znamená to, že oblast obsahuje důležité informace pro získání informací o intoxikaci alkoholem.

Nejsou přesně testovány úspěšnosti neuronové sítě, ale konvergence vzdělání. Dobrá konvergence znamená, že NN našla dostatečnou korelaci mezi vstupními daty a očekávanými výstupy.


Obrazy se normalizují v měřítku a v poloze, poté se rozkládají v oblastech s rozměry 10 x 10 pixelů. Poté se vyčistí různé oblasti posunutím $X \times X$ okna na celou oblast, čímž vytvoří 100 (10×10) vektor o velikosti $X \times X$. Výsledkem je 200 vektorů pro každou osobu (střízlivý + intoxikovaný).

Přivádějí tyto vektory do [$X \times X$; Y ; 1], neuronová síť ($X \times X$ vstupní neurony, Y neurony ve skryté vrstvě, 1 výstupní neuron), kde Y bylo experimentálně nastaveno, pro každou oblast. Tato neuronová síť má binární výstup: intoxikovaný nebo střízlivý.

Každá oblast je potom zbarvena podle úrovně konvergence, v příkladu na obrázku 13 a obrázku 14 vidíme červené oblasti, ve kterých byla konvergence pod 0,01, žluté oblasti s hodnotami konvergence mezi 0,01 a 0,1 a v modré, s hodnotami nad 0,1.



Obrázek 13: Konvergence barevných matic s oblastmi 3x3



Obrázek 14: Konvergence barevných matic s oblastmi 7x7

Experiment byl proveden pro obě matice s oblastmi $X=3$ a $X=7$, respektive $Y=30$ a $Y=49$. Vycházejí z toho výsledky, že nejvyšší konvergence je dosažena pro čelo a nos, čímž se tyto části tváře stanou dobrými kandidáty pro detekci intoxikace.


V další části aplikují obdobný postup na celou tvář, konkrétně na vybranou oblast uprostřed obličeje o rozměrech 50x100 px (5000px).

Tato oblast o šířce 5000 pixelů je opět potlačena pomocí $X \times X$ okna pro intoxikovaný a střízlivý obličej každého člověka, čímž se získá 10000 $X \times X$ vektorů pro každou osobu. Pro tytéž hodnoty X a Y jako dříve byla jedna neuronová síť natrénována s těmito 10000 vektory pro každou osobu.

Síť byla poté testována na datech, které byly vyškoleny. Výsledky jsou prezentovány tak, jak je znázorněno na obrázku 15 a obrázku 16, černý pixel znamená, že oblast $X \times X$ umístěná na tomto pixelu byla identifikována neuronovou sítí jako střízlivá, zatímco bílá znamená, že byla identifikována jako intoxikovaná. Vlevo (a) jsou střízlivé tváře, vpravo (b) intoxikované.



Obrázek 15: Výsledky získané u 3x3 oblasti



Obrázek 16: Výsledky získané u 7x7 oblasti

Po perfektním rozlišení by střízlivá tvář byla celá černá a intoxikovaná alkoholem byla celá bílá. Je zřejmé, že rozdíl mezi střízlivým a intoxikovaným alkoholem, je významný. Také se ukazuje, že čím větší je vstup, tím lepší jsou výsledky. Po změření pěti různých osob, byly získány tyto výsledky, které můžeme vidět v tabulce 2.

Tabulka 2: Průměrná míra úspěšnosti pro 5 testovaných subjektů s příslušnou oblastí

<i>Střízlivý (3x3)</i>	<i>Intoxikovaný (3x3)</i>	<i>Střízlivý (7x7)</i>	<i>Intoxikovaný (7x7)</i>
76,02 %	69,10 %	92,01 %	87,20 %

Zajímavějším výsledkem by bylo procento pixelů, které by v obou případech poskytly správné výsledky (protože například 50 % a 50 % úspěšnosti by stále znamenalo, že 0 % obrazových bodů pomůže rozlišovat mezi střízlivými a intoxikovanými).

Poté byl postup opakován, ale tentokrát s využitím sítě, která byla praktikována pro jednu osobu na všech ostatních subjektech, aby byla zjištěna míra zobecnění. Byly získány výsledky uvedené v tabulce 3.

Tabulka 3: Průměrná míra úspěšnosti pro všechny testované subjekty s pěti různými sítěmi

<i>Střízlivý (3x3)</i>	<i>Intoxikovaný (3x3)</i>	<i>Střízlivý (7x7)</i>	<i>Intoxikovaný (7x7)</i>
61,20 %	55,07 %	69,29 %	63,17 %

Poté byl opakován podobný postup, s tím rozdílem, že bylo sníženo extrakční okno pouze na čelo, jak je znázorněno na obrázku 17.



Obrázek 17: Čelní část vybraná pro analýzu NN

Tentokrát výsledky, které jsou uvedeny v tabulce 4, byly výrazně lepší.

Tabulka 4: Průměrná míra úspěšnosti pro všechny testované subjekty s pěti různými sítěmi zaměřenými na čelo

<i>Střízlivý</i> (3x3)	<i>Intoxikovaný</i> (3x3)	<i>Střízlivý</i> (7x7)	<i>Intoxikovaný</i> (7x7)
93,1 %	84,2 %	78,2 %	73,3 %

Závěr

Z první studie víme jen to, že konkrétní místa, která pomáhají prezentovat korelaci pro konkrétní osobu, nebyla testována.

Ve druhé studii pouze předkládají část pokožky NN a zkoumají, zda celkově, tato část pokožky patří intoxikovanému nebo střízlivému člověku bez ohledu na to, odkud pochází tato oblast.

Jedním velkým problémem je například to, že pokud by jedna část obličeje disponovala studeným teplotním spektrem, když byla střízlivá a negativně korelovala s intoxikací (a to by pro nás bylo zajímavé, neboť stále umožňuje rozlišování), bude to vždycky považováno za střízlivé. Pouze globální korelace, které jsou společné všem částem obličeje (většinou teplotní nárůst), jsou analyzovány touto sítí.

Abychom získali informace o tom, zda je určitá oblast obličeje zajímavá, měli bychom místo toho natrénovat neuronovou síť pro každou oblast (což vyžaduje, abychom dokázali extrahovat přesně stejné oblasti na každé straně). Tato síť by byla odlišná: její vstup by zahrnoval soubor vlastností této konkrétní oblasti (například průměrné hodnoty několika subregionů) a různé vstupní vektory by byly získány extrahováním těchto vlastností od různých jednotlivců.

Na druhou stranu, abychom využili neuronovou síť pro detekci intoxikace (dříve ji používali pouze k určení částí, které jsou předmětem zájmu), mohli bychom vybudovat síť, která bude detekovat zajímavé rysy z předchozí analýzy na celé tváři.

Identifikace alkoholu pomocí infračervených snímků založených na funkcích DCT v doméně DWT

V [5] je zvolen vysoce abstraktní přístup, nejprve změnou domény reprezentace obrazu na doménu DWT (Discrete Wavelet Transform) a následně je aplikována diskrétní kosinová transformace (DCT), aby se předtím data komprimovaly a Support Vector Machine (SVM), který pak klasifikuje intoxikované a střízlivé jedince.

Diskrétní Wavelet transformace rozkladu

Prvním krokem bylo transformovat obraz přes DWT, což umožňuje studovat obraz v prostorové oblasti.

Transformace Wavelet je běžná technika zpracování signálu a obrazu, často používaná při kompresi dat, podobně jako Fourierova transformace, ale s použitím časově umístěných vlnek (tzv. Wavelets) namísto nekonečných $e^{j2\pi ft}$ Fourierových vlnek, umožňujících dočasné rozlišení, nebo případ zpracování obrazu: prostorové rozlišení.



Obrázek 18: Zastoupení 2-úrovňového 2D DWT

Část, která bude zachována pro další zpracování, je přibližně dílčí pásmo v levém horním rohu obrázku na obrázku 18.

Snížení dimenze pomocí diskrétní kosinové transformace

Po DWT ještě nebyly žádné funkce extrahovány. Proto byla provedena extrakce použitím DCT na přibližné dílčí pásmo.


Reprezentace kmitočtových domén, jako jsou Fourierova nebo Cosinova transformace, jsou velmi účinné pro shromažďování informací, protože výrazně snižují redundanci v transformovaných datech. Kapacita informací o zabalení DCT, se blíží schopnosti PCA (Principal Components Analysis). DCT používáme nad PCA, protože je snazší porovnávat dva výsledky DCT. Jelikož koeficienty jsou vyjádřeny na stejném základě (kosinové vlny).

Po tomto DCT se extrahují první v získané hodnoty, podle toho se nazývá „skenování Z“, vyberou se hodnoty v sestupném pořadí blízkosti původu. Budou zkoumány různé hodnoty, aby bylo vidět, které z nich jsou relevantní pro identifikaci intoxikace.

Support Vector Machine klasifikace (SVM)

Data byla klasifikována pomocí SVM. SVM je složitá datová struktura, jejímž cílem je mapovat vstupní data do velkého rozměrového prostoru a nakreslit do klasifikační roviny, která nejlépe klasifikuje dvě dané třídy (zde intoxikované alkoholem a střízlivé). Tato klasifikační rovina bude rozhodovací hranicí, která je v podstatě ekvivalentní prah, ale ve velkých rozměrech. SVM, BPNN a LDA (lineární diskriminační analýza), i když jsou odlišné, jsou všechny použity pro klasifikační problémy jako je tento.

Tento SVM má v -dimenzionální vstup, kde vstupní data jsou koeficienty extrahovány z DCT, jeho výstup je binární, buď střízlivý nebo intoxikovaný. Poté pokračovali v testování účinnosti SVM pro různé hodnoty v , vykazují přesnost získanou v podle grafu znázorněného na obrázku 19.



Obrázek 19: Přesnost rozlišení SVM podle v

Nejvyšší přesnost byla dosažena 6 koeficienty, kde dosáhla 98,5 % úspěšnosti. Z tohoto grafu se může vyvodit, že koeficienty 1 až 6 zlepšují výsledky, zatímco 10 a 11 je zhoršují. 7 až 9 a 12 + se zdají, že nemají téměř žádný účinek.

Závěrem je, že výsledky jsou porovnány s výsledky získanými metodou BP-NN [4] a vzhledem k velikosti dat je možné získat až 2 % rozdíl (98,5 % až 96,25 %).

Závěr

Tato studie nabízí efektivní výsledky, protože navrhovaná metoda prokázala vysokou přesnost v rozlišení, aniž by se spoléhala na známý střízlivý termogram identifikované osoby. Holistický aspekt této metody také činí méně citlivý na rozdíly v normalizaci obrazu (které budou indukovány algoritmy detekce obličeje), je to mnohem spolehlivější.

Bylo by také zajímavé otestovat tento postup se SVM na více než dvou třídách (střízlivý a intoxikovaný), aby bylo možné rozlišit různé střední úrovně intoxikace.

Na druhé straně se nesmí zapomínat na to, že údaje použité v této studii nebyly reprezentativní, protože všechny obrázky intoxikované osoby, byly pořízeny pouze na jedné osobě, což naznačuje, že síť by mohla být více vyškolená, aby rozpoznala určitou tvář pod alkoholem než rozpoznat samotnou intoxikaci. Také, jelikož rozlišovací charakteristické pole po DCT je velmi nízké (pouze šest hodnot), pravděpodobně bychom mohli použít rozlišovací analýzu k definování intoxikovaného prostoru (podobně jako [3]), pokud nechceme používat SVM.

Závěry řešerše a budoucí perspektivy

Z tohoto přehledu se shrnou různé techniky a myšlenky, které jsou považované za důležité pro intoxikaci alkoholem z IR snímků.

Lineární diskriminační analýza na specifických místech obličeje, jak byla provedena v prvním postupu [4]. To by bylo zajímavé za předpokladu, že můžeme najít účinný algoritmus rozpoznávání obličeje, aby se získali stejné funkce na každé jiné tváři. V opačném případě by se mohla použít metoda extrahování hrubších čar, podobně jako jednoduché rozdělení mřížky po normalizaci ve středovém měřítku, ale pravděpodobně by se ztratila přesnost.

Lineární diskriminační analýza diferenciálních vztahů specifických oblastí obličeje, hlavně čelist-nos/ústa, pro další posun výsledků získaných při druhém postupu [4].

Analýza založená na extrakci faciálního cévního systému, pokud můžeme studovat, na kterých faktorech se viditelnost cév liší mezi jednotlivci, možná nalezneme konstantu, která umožní vybudovat

stabilní identifikační techniku z extrakce krevních cév, nebo alespoň jej extrahovat jako zajímavou vlastnost.

SVM analýza DCT koeficientů v DWT oblasti, protože tato metoda vypadala, že poskytuje dobré výsledky v [7]. SVM by se mohla nahradit jednodušším řešením, jako je LDA, pokud to bude nutné.

Analyzované studie se zaměřují pouze na binární klasifikaci, střízlivou nebo intoxikovanou, která je daleko od objektivního měření. Důležitý aspekt je spojen s časově závislou alkoholovou intoxikací, časově prediktivní model, který dokáže provést korelaci mezi příslušným IR obrazem a množstvím alkoholu. Takový přístup by významně přispěl k objektivizaci množství alkoholu z rozložení teploty při pití osoby. Na druhou stranu, teplotní mapa závisí na mnoha aspektech, včetně okolních teplotních podmínek, termoregulaci a sklonu k alkoholu. Důležitým aspektem je i zbytkový alkohol a jeho detekce.

2 Současné metody segmentace obrazu v lékařství

Diagnostické zobrazování je důležitým nástrojem v medicíně. Magnetická resonance, počítačová tomografie a digitální mamografie, jsou neinvazivní prostředky pro mapování anatomie a ulehčují diagnostiku a následnou léčbu. Vzhledem k náročnosti snímků, je třeba obraz počítačově zpracovat a analyzovat. Využívají se k tomu speciálně navržené algoritmy, které se soustředí na vymezení anatomických struktur a dalších oblastí zájmů. Algoritmy pro segmentaci obrazu hrají zásadní roli v mnoha aplikacích biomedicínského zobrazování, jako kvantifikace tkáňových objemů, diagnóza, lokalizace patologie, studie anatomických struktur, plánování léčby a vedení pro počítačovou chirurgii. Tento článek poskytuje přehled současných nejpoužívanějších metod zpracování obrazu.

2.1 Definice obrazu

Obraz je soubor měření ve 2D nebo 3D prostoru. V lékařství, to je měření intenzity absorpce RTG záření, akustického tlaku ultrazvuku, nebo amplitudě rádiové frekvence v magnetické resonance. Pokud je provedeno jedno měření, pro každou zobrazenou oblast získáme skalární obraz. Pokud je provedeno více měření, získáme vektorový obraz nebo vícekanálový obraz. Ve 2D zobrazení se obrazové body nazývají pixely. Ve 3D zobrazení se body nazývají voxely. Pro zjednodušení používáme pixely i u 3D zobrazení. Segmentace obrazu je rozdělení obrazu podle homogenních míst se stejnou intenzitou a texturou.


2.2 Rozměrnost (Dimensionalita)

Rozměrovost odkazuje na to, zda segmentační metoda funguje jako 2D obrazová doména nebo 3D obrazová doména. Metody, které se spoléhají výhradně na obrazové intenzity, jsou nezávislé na doméně obrázku. Nicméně některé metody, jako je deformovatelný model, Markov random field (MRFs) a zvětšování oblasti, zahrnují prostorové informace a mohou proto fungovat odlišně v závislosti na dimenzionálním obraze. Obecně platí, že metody 2D jsou aplikovány na obrázky 2D a 3D metody jsou použity na 3D obrazy. V některých případech se však 2D metody aplikují postupně na řezy 3D obrazu ^[20, 21].

Unikátní situace, ke které dochází v segmentaci lékařských obrazů, je vymezení regionů na neeuclidovské doméně, jako je rozdělení mozkové kůry ^[22, 23]. To je v podstatě segmentace na povrchu měření. Protože povrch je 2D objekt, skládaný v 3D prostoru, segmentace na povrchu nelze léčit jako standardní 2D nebo 3D problém. Modelování prostorových charakteristik podél povrchu je mnohem obtížnější než ve standardní zobrazovací rovině, kvůli nepravidelného odběru vzorků síťové reprezentace. ^[24]

Efekty s částečným účinkem jsou artefakty, na jednom pixelu, k nimž dochází při různých typech tkání, což vede k rozostření intenzity. Obrázek 20 ukazuje, jak může proces odběru vzorků vést k efektu s částečnými účinky, nejednoznačnosti ve strukturálních definicích. Efekty s částečným účinkem jsou běžné lékařské snímky, zejména 3D CT a MRI data, ve kterých rozlišení není izotropní a v mnoha případech je poměrně špatná podél jedné osy obrazu.

Nejběžnější metodou k řešení efektů s částečnými účinky je vytváření segmentací, které umožňují překrývání oblastí nebo tříd, nazývaných měkké segmentace.



Obrázek 20: Ilustrace vlivu efektu s částečnými účinky, (a) ideální obraz, (b) získaný obraz

Standardní metody používají „tvrdé segmentace“, které vynucují binární rozhodnutí o tom, zda je pixel uvnitř nebo vně objektu. Měkké segmentace si naopak zachovávají více informací z původního obrazu tím, že povolují nejistotu v umístění hranic objektů. ^[29]

2.3 Intenzita nehomogenity

Hlavní komplikovanost, která je specifická pro segmentaci MR obrazů, je intenzita nehomogenních artefaktů, který způsobuje, že se na obrazovce objevuje efekt stínování obrazů. Artefakt může výrazně degradovat výkonnost metod, které předpokládají že hodnota intenzity třídy tkáně je konstantní na obrázku. Ačkoli zlepšení technologie skeneru snížilo tento artefakt, nehomogenita zůstává problémem zejména u snímků získaných použitím povrchových cívek.

Metody, které současně segmentují obrázek a odhadují nehomogenitu, nabízejí výhody jako je schopnost využívat průběžné informace získané ze segmentace. ^[25, 26]

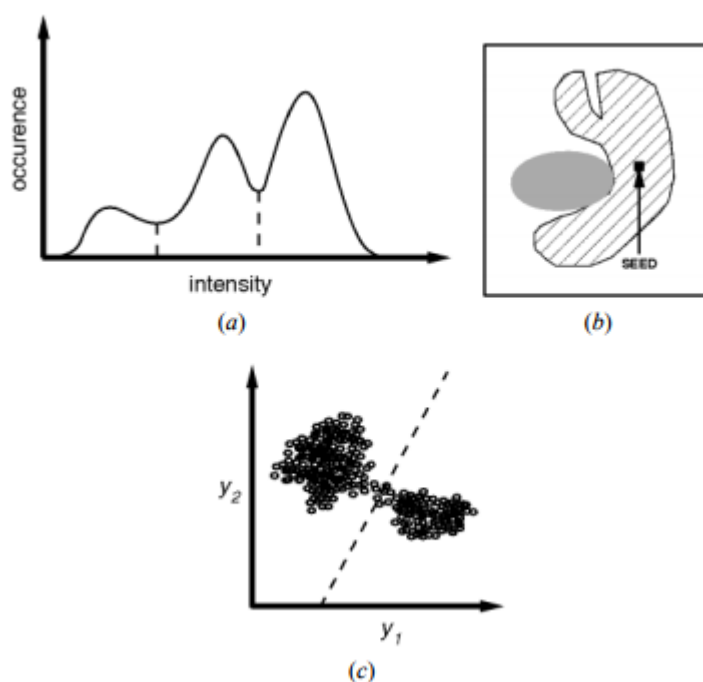
Existují dva postupy pro modelování nehomogenity v metodách, které provádějí současnou segmentaci. První postup předpokládá, že průměrná intenzita pro každou třídu tkání je prostorově rozmanitá a tyto míry intenzity jsou navzájem nezávislé. Druhý postup modeluje nehomogenitu, jako pole multiplikačního zisku nebo pole přídavné zaujatosti obrazu logaritmus. Není jasné, který z těchto dvou způsobů poskytuje přesnější modelování nehomogenních účinků, i když druhý postup má být výpočetně levnější. Druhý postup může být také použit pro odstranění nehomogenity. ^[27, 28, 29, 30, 31]

2.4 Metody

Definujeme každou metodu, její implementaci, výhody a nevýhody. Každá technika je popsána samostatně, ale často se používají různé techniky, pro různá řešení segmentačních problémů. Metody segmentace rozdělujeme do osmi kategorií: 1. prahové přístupy, 2. přístupy zvětšování oblasti, 3. klasifikátory, 4. klastrování, 5. Markov Random Field model (MRF), 6. umělé neuronové sítě, 7. deformovatelné modely a 8. přístupy řízené atlasy. Z těchto metod lze považovat metodiku prahování, třídění, seskupování a MRF za metody klasifikace pixelů.

2.4.1 Prahování (Thresholding)

Prahování se blíží k segmentaci pomocí binarizace obrazu. Pomocí prahování určíme hodnotu intenzity, která nám oddělí části obrazu. Pixely s větší intenzitou, než prahová hodnota, budou mít ve výsledku maximální intenzitu a pixely s nižší intenzitou budou mít intenzitu nulovou. Pokud použijeme více prahových hodnot, této metodě se říká multiprahování. Prahování je jednoduchou a efektivní metodou pro segmentaci obrazu různých struktur s určitou intenzitou. Zvolit prahové hodnoty lze automaticky, nebo interaktivně po vizuální kontrole výstupního obrazu. Prahování je jedna z prvních úprav obrazu, při jeho zpracování. Je aplikován v digitální mamografii, kde dokáže odhalit maligní a benigní tkáň. Bohužel má své nevýhody v případě, kde se v obraze vyskytuje mnoho šumu či artefaktů. [32]



Obrázek 21: Metody prostorových prostorů a zvětšování oblasti, (a) histogram zobrazující tři zjevné třídy, (b) 2D funkční prostor, (c) příklad zvětšování oblasti.

2.4.2 Zvětšování oblasti

Je to technika pro extrakci oblasti s předem stanovenými kritérii, jako intenzita nebo ohraničení. Nejjednodušší je nechat uživatele vybrat počáteční bod a podle něj se vybere celá oblast, které je tento bod součástí. Podobně jako thresholding se tato metoda nevyužívá samostatně, ale společně s dalšími metodami. Hlavní nevýhoda této metody je nutnost zásahu uživatele v podobě vybírání referenčního bodu. Tato metoda je citlivá na obrazové artefakty a šum. [33, 34]

2.4.3 Klasifikátory

Jsou to rozpoznávací metody pro dělení oblasti proti vzoru. Tato metoda potřebuje pro své „naučení“ manuálně segmentovaný obraz. Klasifikátory kontrolují oblasti se stejnou strukturou, ze kterých pak vytváří jednotlivé segmenty. [35]

2.4.4 Klastrování

Fungují stejně jako klasifikátory, s rozdílem, že se nepotřebují učit pomocí manuální segmentace obrazu. K-means algoritmus sdružuje pixely okolo střední intenzity v daném okolí, fuzzy C-means algoritmus zobecňuje K-means algoritmus založený na technice fuzzy množin. Odhadnou se jednotlivé části na základně Gaussian mixture model. Tato metoda má výhodu v rychlosti zpracování dat a je docela odolná proti šumu v obraze, pomocí MRF (Markov Random Field) modelování. [28]

2.4.5 Markov Random Field model

MRF není metodou segmentace, ale statistický model, který je využíván při segmentaci. Modelují prostorové interakce mezi sousedními nebo blízkými pixely. V lékařských zobrazeních je tato metoda používána, protože sousední pixely se většinou řadí do jedné třídy. V praxi to znamená, že žádná anatomická struktura není zobrazena pouze jedním pixelem. Tato metoda se často používá při klastrování jako K-means algoritmus. Tato metoda je odolná šumu a jediný problém této metody je obtížnost zvolit správné parametry prostorových interakcí. Při výběru vysokých hodnot, celá struktura bude vyhlazena a ztratí se důležité detaily segmentace. A celkově je náročná na výpočetní výkon. I přes tyto nevýhody je tohle jedna z nejpoužívanějších metod pro klasifikaci a pro modelování intenzit nehomogenity na MR obrazech. [31]

2.4.6 Umělé neuronové sítě

Umělé neuronové sítě (ANN) jsou paralelní sítě procesních prvků nebo uzlů, které simulují biologické učení. Každý uzel v ANN je schopen provádět elementární výpočty. Učení se dosahuje přizpůsobením váhy přiřazené ke spojům mezi uzly. Nejrozšířenějším používáním v medicíně je klasifikace, ve které jsou váhy určovány pomocí výcvikových dat a ANN je pak použita k segmentaci nových dat. ANN mohou být také používány bez dohledu jako metoda klastrování. Zpracování je paralelní, ale simulace se provádí sériově, i když se nevyužívá veškerý výkon. [36, 37]

2.4.7 Deformovatelné modely

Technika pro vymezení ohraničení regionu pomocí křivek nebo různou deformací povrchů. Pro vymezení hranic objektu musí být uzavřená křivka anebo povrch umístěn u námi požadované hranice která se nechá pojit relaxačním procesem. Tyto modely se využívají pro rekonstrukci mozkové kůry v MRI obrazech, anebo pro segmentaci cév a kostí u počítačové tomografie a ultrazvuku. Tato metoda má využití i u sledování průběhů v čase, které se využívá u ultrazvuku. Jejich nevýhoda spočívá v manuálním výběru oblasti, kterou chce ohraničit. [38, 39, 40]

2.4.8 Atlasově řízené přístupy

Jsou to výkonné nástroje pro segmentaci obrazu, pokud je k dispozici šablona. Atlas je generován ze sestavených anatomických informací, které jsou vyžadovány při segmentaci. Tento atlas je pak využit jako reference pro segmentaci nových obrazů. Tato metoda je velmi podobná klasifikování, ale používá se spíše v prostorové doméně. Segmentace je prováděna podle vzoru z dříve zpracovaných anatomických dat, které se využijí jako šablona pro segmentaci aktuálního obrazu. Nejlépe se tato metoda využije při zpracování struktur, které jsou shodné u všech lidí, jako například segmentace mozku. [41, 42, 43]

2.4.9 Ostatní metody

Modelování je metoda segmentace, která využívá jednoduchých geometrických obrazců jako elipsa nebo parabola pro lokalizaci segmentů. Tato metoda se zaměřuje na struktury, podle kterých je segmentace prováděna a má dobré výsledky.

Watershed algoritmus využívá detekce ohraničení a matematické morfologie k rozdělení obrazu na homogenní oblasti. Tato metoda trpí při zvolení mnoha oblastí určených k segmentaci. Po použití této metody se musí obraz nadále zpracovat tak, že se spojí několik segmentů do jednoho o dané struktuře.

Závěr

Budoucnost segmentace medicínských obrazů je založena na přesnosti, preciznosti a rychlosti využívání segmentačních metod s omezením lidských zásahů. Pro rychlejší zpracování obrazu se využívá paralelizace, pro přesnost je vhodné využít atlas.

3 Genetické algoritmy

Na principu genetických algoritmů je dnes možné optimalizovat procesy, řídit systémy a selektovat nejvhodnější varianty z hojného množství řešení. U genetických algoritmů platí, že čím je zadaná úloha složitější, tím kvalitnější bude řešení.

Výhoda je v rychlosti výpočtu dané úlohy a také pracovat s obrovským množstvím položek s desítkami či stovkami podmínek. ^[44]

3.1 Princip fungování genetických algoritmů

Pro realizaci genetického algoritmu musíme definovat dvě základní věci:

- Genetickou reprezentaci řešeného problému
- Hodnotu funkce Fitness pro splnění ukončovací podmínky

Standardní představitele může tvořit např. řetězec či pole bitů. V praxi se velmi často využívají binární řetězce.

Poté co jsou definované obě podmínky, se může začít s inicializací počáteční generace. Ta je generována náhodně, aby byla rovnoměrně pokryta všechna možná řešení. Velikost počáteční populace může být různá, většinou jde o stovky až tisíce možných řešení. Všechny generace (všechna možná řešení) se nazývají stavový prostor.

Na začátku (tzn. v první (inicializační) generaci) je populace složena z naprosto náhodných členů. Pro každého jedince se spočítá „fitness funkce“ (vyjadřuje kvalitu řešení reprezentovaného tímto jedincem). Podle fitness funkce jsou vybráni jedinci, kteří se dále budou upravovat pomocí mutací a křížení, tím vznikne nová populace. Tento postup se pravidelně opakuje, díky tomu se kvalita řešení v dané populaci postupně vylepšuje. Celý proces se zastaví, jakmile bude dostačující kvalita řešení, popřípadě po předem dané době. ^[44]

Vlastní genetický algoritmus má sedm kroků:

1. Návrh struktury
2. Inicializace
3. Ohodnocení
4. Selektce
5. Křížení
6. Mutace
7. Reprodukce

3.1.1 Návrh struktury

Je nutné navrhnout strukturu jedince, aby se snadno dala vyjádřit jeho kvalita a současně se dobře provádělo křížení. Pro tento účel je zvolena generace osmi řetězců, která je reprezentovaná binárním kódem. ^[44]

3.1.2 Inicializace

Inicializace – počáteční nastavení vektorů, které tvoří daného jedince. Převážně se jedná o náhodné hodnoty. První generace je vytvořena s použitím generátoru náhodných čísel, který je uveden na obrázku 22. ^[44]

11110011
01010101
00011101
00111001
01100000
10000011
00000111
11111000

Obrázek 22: Náhodná generace

3.1.3 Ohodnocení

Zde se vypočítává kvalita jedince (v případě binárního čísla se jedná o dekadické vyčíslení). Případně u řešení úloh, kde se objevují „špatní“ jedinci, jejich kvalitu penalizujeme. Těmto jedincům je snížena šance dostat se do další populace, popřípadě se nahradí novým jedincem. Funkce f vypočítá, jak kvalitní řetězce máme k dispozici.

$f(11110011) = 1,794$
$f(01010101) = 8,889$
$f(00011101) = 4,031$
$f(00111001) = 6,943$
$f(01100000) = 9,389$
$f(10000011) = 9,992$
$f(00000111) = 1,067$
$f(11111000) = 1,067$

Obrázek 23: Fitness jedinců

Jak můžeme vidět na obrázku 23, máme tři poměrně silné řetězce (2, 5 a 6), ale také tři řetězce s horšími výsledky (1, 7 a 8). Cílem bude vytvořit novou generaci, která se bude skládat z kombinace nejsilnějších řetězců (2, 5, 6). Proces tvorby nové generace se skládá ze tří kroků: selekce, křížení a mutace. ^[44]


3.1.4 Selekcce

V tomto kroku se kopírují vybrané řetězce ze staré generace do nové generace. Výběr je závislý na pravděpodobnosti vylosování řetězce při tzv. vážené ruletě. Tu si můžeme představit jako obyčejnou ruletu, ale s tím rozdílem, že každý řetězec nemá stejnou pravděpodobnost vylosování. Pravděpodobnost pro daný řetězec je vypočítán tak, že se sečtou všechny fitness hodnoty a výsledným číslem hodnotu fitness pro určitý řetězec podělíme.

Tabulku s výpočtem pravděpodobnosti a její graf můžeme vidět na obrázku 24 a obrázku 25. ^[44]

Řetězec	F
00111001	6,943
01010101	8,889
01010101	8,889
10000011	9,992
01100000	9,389
10000011	9,992
00000111	1,067
01100000	9,389
Průměrná	8,069
kvalita	

Obrázek 24: Výpočet pravděpodobnostních hodnot pro ruletu




Obrázek 25: Graf vypočtené pravděpodobnosti pro ruletu

Ruleta se musí osmkrát roztočit a vylosují se osm členů nové generace. Nemůžeme však získat tímto způsobem lepší generaci (množinu kvalitnějších řešení), než byla na začátku. V této generaci se pouze nevyskytují nejslabší jedinci. Proto se používají dále ještě křížení a mutace. ^[44]

3.1.5 Křížení

Zde dochází k výměnám informací mezi dvěma řetězci. Na začátku jsou vybrány dva náhodné řetězce z nové generace, u kterých bude probíhat výměna (viz. obrázek 26).



Obrázek 26: Schéma křížení

Tímto vzniknou dva nové řetězce, které obsahují některé informace od svých předků. Jednotlivý jedinci, mají poté fitness kvalitu následující:

1. $f(00000000) = 0$
2. $f(01100111) = 9,631$

Můžeme si všimnout, že první vytvořený potomek se opět nemůže dostat do procesu selekce a mutace. ^[44]

3.1.6 Mutace

Selekcí a křížením nedosáhneme kvalitních výsledků ani při vhodném výběru jedinců v generaci. Můžeme mít podmínku, která říká, že kvalitní řetězec musí obsahovat jedničku na čtvrté pozici. Jestliže takový řetězec nemáme, můžeme si ho dostupnými kroky vytvořit. Když např. zmutuje řetězec 01100111, na čtvrté pozici dostaneme 01110111 – zde nám mutace pomohla v tvorbě kvalitnějšího řetězce. ^[44]

3.1.7 Reprodukce

Poslední fází při tvorbě nové generace je reprodukce. Zde jsou vybrány pro předchozí operace (selekce, křížení a mutace) řetězce, které mají nejvyšší fitness hodnotu. V opačném případě, ty řetězce, které by nebyly ziskem do další fáze, se nahradí kopiemi silnějších jedinců. ^[44]

3.2 Využití genetických algoritmů

Můžeme je využít k řešení širokého spektra úloh. Základní podmínkou je definice funkce, kterou musíme minimalizovat či maximalizovat. U minimalizace se obvykle jedná o snížení odchylky od požadovaného stavu, minimalizace spotřeby energie a minimalizace nežádoucích účinků. Při maximalizaci se jedná o zvyšování účinnosti a zisku.

K úspěšné implementaci genetických algoritmů je podmínka zabezpečit, aby byl optimalizovaný problém kvalitně počítačově reprezentován. Tzn. pro každý bod potencionálního řešení bude možné počítačem zhodnotit míru (ne)úspěšnosti splnění daného cíle. Zároveň, ale nezáleží na typu daného procesu (ekonomický, fyzikální nebo biologický). ^[44]

3.3 Výhody genetických algoritmů

Jedna z hlavních výhod, je že v průběhu výpočtu můžeme sledovat, která z podmínek je omezující nebo naopak. Můžeme pak velmi jednoduše zasáhnout, tak že se změni priority nebo podmínky a poté pokračovat ve vyhledávání přípustného řešení bez ztráty informací z dosavadního průběhu informací.

U konvenčních optimalizačních metod při změně podmínek musíme celý výpočet opakovat od začátku.

Existují problémy, které jsou těžko řešitelné nebo dokonce vůbec s použitím konvenčních přístupů a metod. Tady lze můžeme využít genetické algoritmy. Mezi problémy patří: hledání globálních extrémů nelineárních multimodálních funkcí, těžké kombinatorické nebo grafově orientované problémy, mnohoparametrové problémy, úlohy s kombinovanými typy proměnných,

úlohy s velkým počtem různých typů omezení a úlohy s výpočetně náročným vyhodnocením účelové funkce. ^[44]

Závěr

Genetické algoritmy se už dnes používají v několika praktických aplikacích. Umožňují řešení v podstatě jakékoli výpočetní úlohy, ale největší účinnost se očekává, tam kde jsou známy dostatečné počty podmínek a jednotlivých řešení.

Proto se genetické algoritmy nepoužívají u těch typů úloh, které se dají vyřešit klasickou metodou. Genetické algoritmy mají uplatnění téměř ve všech oblastech, kde nemůže být použita klasická metoda řešení. ^[44]

4 Analýza IR záznamů

Alkohol působí na každý lidský organismus jinak. Změnu můžeme pozorovat například ve změně tlaku, pulsu, ale také se mění naše teplota. Největší změny teplot můžeme pozorovat na čele a na nose (kde určité spektrum teplotní mapy bude expandovat). Níže jsou uvedeny všechny data, které se měřily, po každém požitém množství alkoholu.

DATOVÁ STRUKTURA

Záznamy pacientů jsou uloženy v souboru: data_structure.mat.

Struktura obsahuje následující parametry:

pohlaví: w-žena, m-muž

stáří

výška [m]

váha [kg]

med: trvale užívané léky (např. antikoncepce nebo pilulky proti alergii)

tw [cm]: délka od špičky nosu po obočí

time_no_food [h]: doba před měřením, kdy testovaná osoba nejedla

alcohol_breath [%]: alkohol v dechu

puls [bpm]

sys [mmHg]: Systolický tlak


dias [mmHg]: Diastolický tlak

V tabulce 5 můžeme vidět datovou strukturu 5-ti náhodně vybraných probandů z 20-ti celkových.


Tabulka 5: Záznamy 5-ti náhodně vybraných probandů

	1	2	3	4	5
Pohlaví	w	m	m	m	m
Stáří	47	23	27	42	25
Výška	1,72	1,82	1,69	1,82	1,93
Váha	100	90	80	88	83
Med	-	-	-	-	-
Tw	4,7	5,1	4,5	5	4,8
Time_no_food	4,5	2	2	2,5	3
Alcohol_breath	[0 0,16 0,26 0,42 0,55 0,59]	[0 0,01 0,16 0,39 0,52 0,69]	[0 0,2 0,34 0,41 0,61 0,78]	[0 0,17 0,21 0,28 0,33 0,6]	[0 0,09 0,21 0,4 0,55 0,63]
Puls	[93 87 86 82 79 77]	[66 63 70 71 73 77]	[50 63 56 63 64 65]	[80 79 79 78 75 75]	[88 84 81 81 77 76]
Sys	[136 136 130 120 120 119]	[135 135 127 121 121 120]	[109 100 99 97 95 94]	[161 158 157 157 150 149]	[130 125 112 115 115 110]
Dias	[86 86 81 77 77 75]	[85 74 81 72 70 70]	[79 75 69 68 67 59]	[99 97 95 95 94 90]	[89 87 73 69 70 68]


Na obrázku 27 si můžeme všimnout, že puls u probandů 1, 4 a 5 má sestupnou tendenci. Naopak u probandů 2 a 3 je ze začátku měření puls kolísavý a poté má vzestupnou tendenci.



Obrázek 27: Závislost pulsu na množství alkoholu v krvi



Obrázek 28: Závislost systolického tlaku na množství alkoholu v krvi



Obrázek 29: Závislost diastolického tlaku na množství alkoholu v krvi

U systolického tlaku na obrázku 28 vidíme, že křivky mají jen sestupnou tendenci a u diastolického tlaku na obrázku 29 můžeme vidět, že všechny křivky, mají také sestupnou tendenci, až na křivku u probanda 2, která je na začátku měření kolísavá a až po 80 ml alkoholu, je křivka sestupná.

Průměrný věk všech 20-ti probandů je 32,5 let.

Všechny osoby byly měřeny v předem definovaných stabilizovaných podmínkách: teplota – 20 °C, vlhkost – 50 %.

Po příjezdu na místo měření, osoby, na nichž bylo prováděno měření, odpočívaly 30 minut, aby se stabilizovala jejich teplota a vyloučil se vliv venkovní teploty. Data probandů jsou uloženy v souborech .mat s strukturou: probxa_n. Kde x označuje pořadí probanda a n je pořadí měření. Probandi konzumovali 38% alkohol. Časová prodleva mezi individuálními dávkami alkoholu byla 30 minut ((1) 30 minut (2) 30 minut ... 30 minut (6)).

Proces měření byl následující:

(n) – n označuje pořadí měření

(1) proband je střízlivý


(2) 40 ml množství alkoholu

(3) 80 ml množství alkoholu

(4) 120 ml množství alkoholu

(5) 160 ml množství alkoholu

(6) 200 ml množství alkoholu



Obrázek 30: Termografické zobrazení v originálním formátu: a1, bez intoxikace, a2, po 200 ml alkoholu u probanda č.1; b1, bez intoxikace, b2, po 200 ml alkoholu u probanda č.2; c1, bez intoxikace, c2, po 200 ml alkoholu u probanda č.3

Na obrázku 30 máme termografické záznamy tří probandů z 20-ti probandů. Kde vždy na prvním podobrázku je zobrazen snímek, kdy byl proband bez intoxikace a na druhém podobrázku, je zobrazen snímek probanda po vypití 200 ml alkoholu.

Struktura záznamů termografických obrazů


Všechny záznamy byly získány ihned po pití alkoholu. Vzhledem k ochraně osobních údajů musí být všechny záznamy alespoň částečně anonymizovány. Proto byl použit mediánový filtr s maskou konvolučního jádra:10x10. Filtrace má jeden další přínos, totiž teplotní barevná mapa je hladká (barvy jsou promíchané mezi sebou). Na druhou stranu je část původních informací o teplotě zkreslena. Na základě tohoto postupu nemusí být nutně použito předběžné zpracování snímků, které zlepšují obrazové záznamy.

Cíle:

Termografická kamera byla zaměřena na čelo a nos (dle výsledků rešerše tyto oblasti disponují signifikantní změnou teplotní mapy v průběhu intoxikace alkoholem). Proto, je potřeba věnovat pozornost těmto oblastem, aby se získali rysy popisující vliv alkoholu.

5 Předzpracování IR faciálních obrazů

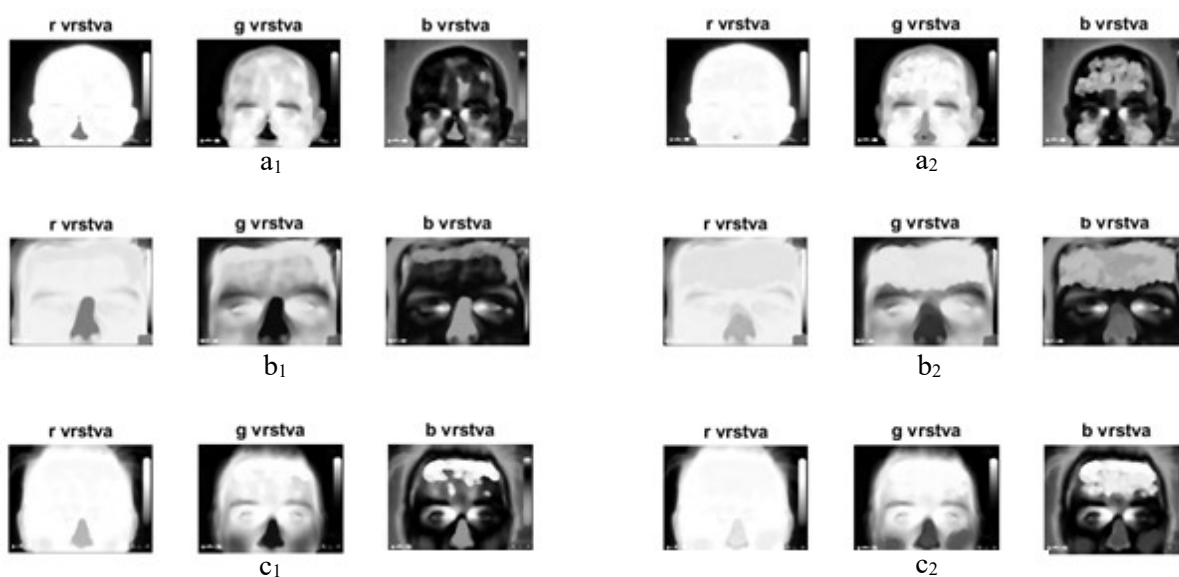
V této kapitole bylo provedeno v programu Matlab předzpracování obrazu, tak že originální termosnímek, byl konvertován do monochromatického zobrazení, který vidíme na obrázku 31. Dále byl každý snímek rozdělen na RGB vrstvu. Důvodem monochromatické konverze je matematická reprezentace obrazu. RGB data jsou reprezentována třemi maticemi, což je z hlediska zpracování obrazu nepohodlné. Monochromatické obrazová data jsou reprezentována 2D maticí. Pro samotnou konverzi z RGB obrazu bylo využito metody váženého součtu jednotlivých chrominačních složek RGB modelu.



Obrázek 31: Termografické zobrazení v monochromatickém formátu: **a₁**, bez intoxikace, **a₂**, po 200 ml alkoholu u probanda č.1; **b₁**, bez intoxikace, **b₂**, po 200 ml alkoholu u probanda č.2; **c₁**, bez intoxikace, **c₂**, po 200 ml alkoholu u probanda č.3

5.1 Dekompozice IR RGB modelu


Základní IR snímek, který je trojrozměrný, je v programu Matlab konvertován do monochromatického snímku (do dvojrozměrného). Následně z monochromatického snímku, je každý rozložen na RGB (red-green-blue) model. Na obrázku 32 můžeme vidět, rozložené snímky na RGB vrstvu, u tří různých probandů, jak bez intoxikace, tak i po 200 ml alkoholu. U R vrstvy nejsou dost viditelné části, které se zahřívají po požití alkoholu. Tudíž pro nás je nepodstatná.



Obrázek 32: Rozložení monochromatického zobrazení na RGB vrstvu: **a₁**, bez intoxikace, **a₂**, po 200 ml alkoholu u probanda č.1; **b₁**, bez intoxikace, **b₂**, po 200 ml alkoholu u probanda č.2; **c₁**, bez intoxikace, **c₂**, po 200 ml alkoholu u probanda č.3

5.2 Extrakce oblasti zájmu

Na obrázku 33 byla provedena, z originálního monochromatického zobrazení, selekce pouze těch částí obličeje, které vykazují dynamické charakteristiky teplotní distribuce v průběhu intoxikace alkoholem nejvíce (čelo a nos).



Obrázek 33: Vybraná část obličeje (čelo, nos): **a₁**, bez intoxikace, **a₂**, po 200 ml alkoholu u probanda č.1; **b₁**, bez intoxikace, **b₂**, po 200 ml alkoholu u probanda č.2; **c₁**, bez intoxikace, **c₂**, po 200 ml alkoholu u probanda č.3

Je zřejmé, že u podobrázku a_2 je zcela zahřátý celý nos jen malá část má stále tmavší barvu (studená část) a například u c_1 a c_2 je teplotní (barevný) rozdíl o hodně menší.

6 Návrh segmentačního algoritmu

Hlavním výstupem této práce je matematický model, umožňující modelování dynamického průběhu teplotní distribuce v průběhu intoxikace alkoholem. K tomuto účelu je využito shlukovací analýzy, konkrétně metody K-means, která je řízena genetickou optimalizací s cílem dosažení kvalitní separace individuálních oblastí teplotní distribuce.


6.1 Algoritmus K-means

Často se používá jako algoritmus shlukové analýzy. Shlukované objekty můžeme chápat jako body v nějakém prostoru. Shluky definujeme svými těžišti, to jsou body, které jsou ve stejném prostoru jako shlukované pixely. Pixely se shromažďují do daného shluku, jehož těžišti jsou nejbližší. Algoritmus K-means na začátku vychází z nějakých (obvykle náhodně zvolených) těžišť a přiřadí do nich body. Tomuto ději říkáme inicializace.

Dále přepočítá vzdálenost pixelů tak, aby shluky pixelů byly co nejbližší k daným těžištím a opět přiřadí body k nově stanoveným těžištím.

Tento děj se děje do té doby, než se těžiště ustálí a shluky pixelů, jsou v minimální délce od daného těžiště.

Poté co se těžiště ustálí a jsou nalezeny minimální vzdálenosti shluků pixelů k danému těžišti, říkáme konvergence.

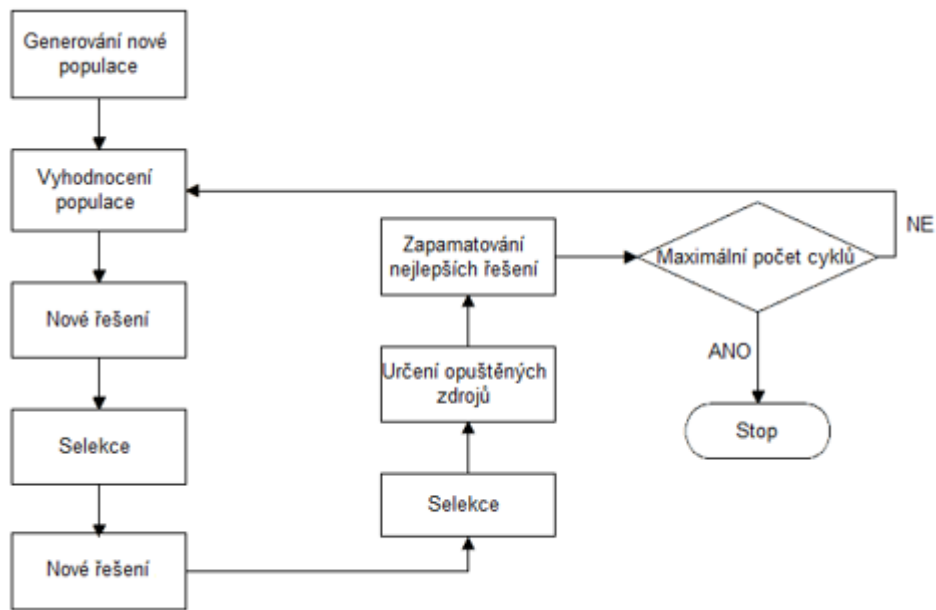


Obrázek 34: Demonstrace algoritmu

Na prvním obrázku z obrázku 34 je zřejmé výchozí těžiště (zde je $T=3$) a náhodně umístěné data v prostoru (shlukované objekty šedé, těžiště barevné). Na dalším obrázku se objekty přiřadí k nejbližším těžištím, čímž vzniknou dané shluky. Dále se přepočtou vzdálenosti shluků k těžištím, aby bylo co nejmenší. A nakonec se kroky 2 a 3 opakují, dokud nedojde k ustálení (konvergence).

6.2 Optimalizace ABC algoritmem

Obecně genetický algoritmus (GA) hledá řešení u složitých problémů, pro které neexistuje použitelný algoritmus. Patří mezi tzv. evoluční algoritmy, které jsou inspirovány přirozenými procesy v přírodě a používají procesy z biologie (dědičnost, mutace, selekce a křížení). Tyto procesy se využívají pro řešení zadané úlohy.



Obrázek 35: Vývojový diagram ABC algoritmu

Stěžejní nevýhodou K-means algoritmu je inicializační definice těžišť jednotlivých regionů, reprezentující oblasti teplotní distribuce. Neexistuje unifikovaný přístup, jak provést optimální rozložení těchto těžišť. V případě nekorektní volby inicializačních těžišť, algoritmus K-means nedosahuje konvergence, což má v praxi za následek nekorektní model teplotní distribuce v průběhu intoxikace alkoholem. Z tohoto důvodu je inicializační volba těžišť řešena na základě genetické optimalizace, která v rámci postupného evolučního cyklu hledá optimalizované řešení na základě vstupních podmínek.

V rámci optimalizace je konkrétně využíváno ABC algoritmu. Algoritmický přístup optimalizace včelím rojem (*ABC* – Artificial Bee Colony), se inspiruje v chování biologických včel a napodobuje některé jeho aspekty (hledající potravu). *ABC* využívá syntetické včely, které jsou rozděleny na tři druhy: zaměstnané včely (*EB*), vyčkávací včely (*OB*) a skauti (*SB*).

Celková populace – S se skládá se stejného počtu *EB* a *OB*. Každé zaměstnané včele (*EB*) náleží jedno prozatímní řešení. Každá *EB* generuje nové řešení V , které sousedí s řešením X a poté tyto dvě řešení pomocí fitness funkce porovná a pokud je řešení fitness funkce V lepší, uchová ho jako nové řešení této dvojice. Pokud lepší řešení nenajde, k žádné změně nedojde. A takto postupuje u každé z dvojic X a V .

EB díky fitness funkce vybere optimálnější řešení z předešlých dvou řešení. Zde se musí uplatnit limit výběru L_v , který stanovuje maximální počet pokusů při výběru řešení X , když stále nelze najít optimální řešení V . využívá se $L_v=10$. jestliže, ani po vyčerpání L_v nelze nalézt optimální řešení, považujeme ho za vyhořelé řešení X_{OUT} .

V další fázi této metody, vyčkávající včely (*OB*) testují dosavadní, jednotlivá řešení z jiných pohledů. Tento výběr označujeme jako ruskou ruletu. Optimálnější řešení má vyšší hodnotu P_i . Které se vypočte následující rovnicí:

$$P_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_j} \quad (3)$$

fit_i – fitness hodnota i-tého řešení

SN – velikost populace

Když je vybráný zdroj potravy X a určený jeho sousední zdroj potravy V , jsou jejich hodnoty fitness porovnány. A i zde jako u první fáze je vybrána hodnota, která má nižší hladinu fitness funkce. Jelikož vypočteme průměrnou hodnotu D_P .

$$D_P = \frac{D_1 + D_2 + D_3 + \dots + D_n}{n} \quad (4)$$

D_P – vzdálenost pixelu od těžiště

V poslední fázi algoritmu jsou skauti (*SB*), kteří hledají nové řešení z výše jmenovaných vyhořelých řešení X_{OUT} . A poté se celý proces opakuje, ale jen pro tyto řešení. Ve finále je vybráno takové řešení, které má minimální hodnotou P_i .

7 Průběh testování

V programu Matlab byly testovány ty části obličeje (nos, čelo), které byly selektovány v kapitole 5.2. Nejprve se muselo najít ideální nastavení shluků pro celé testování, jako nejlepší počet shluků je v tomto případě 8. Dále se určoval velikost populace (počet inicializačních řešení) a počet generací (počet iteračních cyklů ABC algoritmu), v obou případech se nastavilo 100. V tabulce 6 je zaznamenaný výpočetní čas, kdy algoritmus prohledal všechny řešení v daném počtu generací. Všechno testování bylo prováděno na třech vybraných probandech. V následující tabulce 7 a tabulce 8 je zaznamenan výpočetní čas dalších nastavení.

Tabulka 6: Výpočetní čas při nastavení počtu shluků 8, velikost populace 100 a generace 100

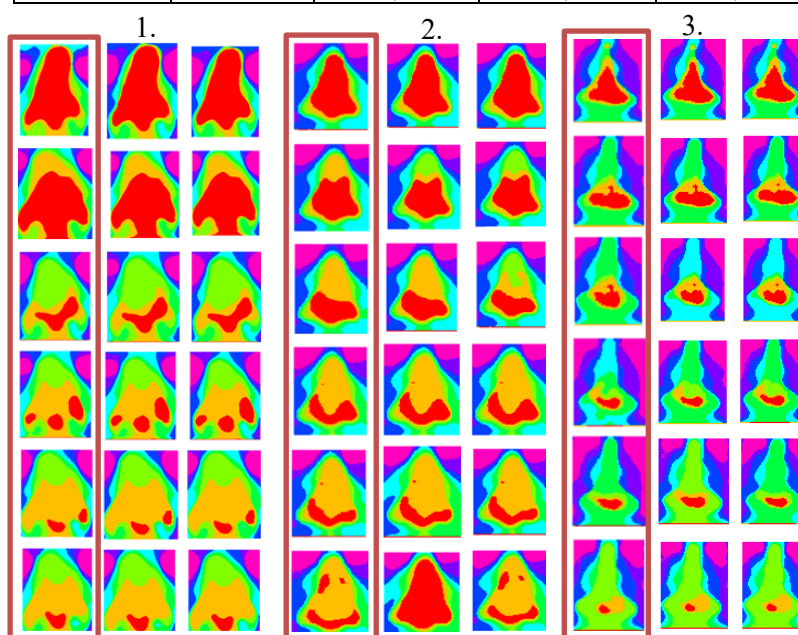
Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	21,97	21,28	17,97
	Čelo	33,27	22,67	20,52
40 ml	Nos	23,66	19,41	17,02
	Čelo	35,48	18,03	20,97
80 ml	Nos	25,83	17,69	18,28
	Čelo	33,67	19,25	20,57
120 ml	Nos	23,01	18,89	19,57
	Čelo	35,89	20,78	19,41
160 ml	Nos	23,09	17,99	18,86
	Čelo	33,43	19,52	20,70
200 ml	Nos	25,87	17,33	18,75
	Čelo	31,87	18,37	19,62

Tabulka 7: Výpočetní čas při nastavení počtu shluků 8, velikost populace 70 a generace 90

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	31,07	15,28	15,14
	Čelo	25,07	16,32	16,75
40 ml	Nos	16,96	15,15	15,97
	Čelo	26,14	17,20	15,41
80 ml	Nos	17,65	15,33	15,64
	Čelo	28,70	14,94	15,42
120 ml	Nos	18,72	14,86	14,98
	Čelo	30,72	15,42	16,70
160 ml	Nos	18,78	15,12	14,02
	Čelo	24,25	16,29	15,72
200 ml	Nos	16,20	15,72	14,83
	Čelo	25,07	15,33	17,16

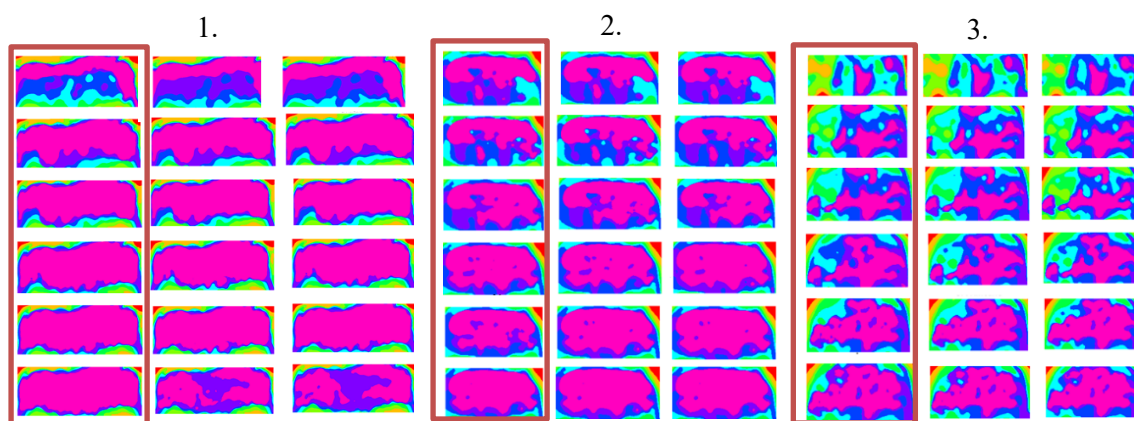
Tabulka 8: Výpočetní čas při nastavení počtu shluků 8, velikost populace 120 a generace 60

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	18,42	14,97	14,98
	Čelo	25,19	16,37	15,75
40 ml	Nos	18,89	14,88	14,58
	Čelo	26,93	15,24	15,43
80 ml	Nos	16,92	15,19	14,87
	Čelo	26,05	16,09	14,76
120 ml	Nos	17,49	14,47	14,96
	Čelo	25,83	16,26	14,97
160 ml	Nos	15,88	13,10	15,14
	Čelo	28,46	14,59	15,04
200 ml	Nos	17,11	14,06	14,21
	Čelo	24,48	15,49	16,78



Obrázek 36: Extrahovány oblasti zájmu (nos) po segmentaci K-means řízeným ABC algoritmem při nastavení 8 shluků, velikosti populace 100, 70 a 120, generace 100, 90 a 60

Zde na obrázku 36 máme srovnání, jak vypadají extrahovány oblasti zájmu – nos. V každé části obrázku je vyznačeno červeným obdélníkem optimální nastavení (8 shluků, velikost populace: 100, generace: 100). Obrázky jsou vždy seřazeny po sloupcích od doby, kdy byl proband bez intoxikace až po požití 200 ml alkoholu, kdy červená barva zaznamenává chlad. U každého probanda, je třikrát změněno nastavení velikosti populace a generace, počet shluků zůstává stejný.




Obrázek 37: Extrahovány oblasti zájmu (čelo) po segmentaci K-means řízeným ABC algoritmem při nastavení 8 shluků, velikosti populace 100, 70 a 120, generace 100, 90 a 60

Zde na obrázku 37 máme srovnání, jak vypadají extrahovány oblasti zájmu od tří probandů – čelo. V každé části obrázku je vyznačeno červeným obdélníkem optimální nastavení (8 shluků, velikost populace: 100, generace: 100). Obrázky jsou vždy seřazeny od doby, kdy byl proband střízlivý až po požití 200 ml alkoholu, kdy růžová barva zaznamenává teplo. Vidíme, že oblast barvy se postupně zvyšuje, jak se postupně čelo zahřívá po požití daného množství alkoholu.


Tabulka 9: Hodnoty fitness při nastavení počtu shluků 8, velikost populace 100 a generace 100

Obsah alkoholu	Extrakce zájmu	Nejlepší hodnota fitness	Střední hodnota fitness	Nejlepší hodnota fitness	Střední hodnota fitness	Nejlepší hodnota fitness	Střední hodnota fitness
		Proband 1		Proband 2		Proband 3	
Bez intoxikace	Nos	1,45	1,82	0,27	0,43	0,24	0,24
	Čelo	3,49	8,74	0,52	1,22	0,10	0,36
40 ml	Nos	1,54	1,55	0,32	0,84	0,27	0,58
	Čelo	2,98	7,67	0,45	0,56	0,27	0,33
80 ml	Nos	1,15	1,54	0,34	0,82	0,26	0,96
	Čelo	2,45	8,00	0,48	1,12	0,43	1,66
120 ml	Nos	1,47	5,20	0,29	0,62	0,29	0,38
	Čelo	3,33	7,66	0,57	1,51	0,66	0,69
160 ml	Nos	0,88	1,90	0,29	0,39	0,27	0,36
	Čelo	2,92	10,14	0,53	1,03	0,55	1,27
200 ml	Nos	0,64	0,93	0,22	0,38	0,12	0,35
	Čelo	2,59	2,78	0,45	1,48	0,51	1,28


Následující výstupy v tabulce 9 prezentují konvergenční charakteristiky fitness funkce v závislosti na počtu generací. Tímto způsobem lze pozorovat a řídit efekt segmentace v závislosti na velikosti fitness funkce. Fitness funkce reprezentuje průměrnou Euklidovu vzdálenost pixelů od shluku. V rámci optimalizace se předpokládá, že nižší hodnota koresponduje s kvalitnějším výsledkem, neboť nízká Euklidova vzdálenost reprezentuje koncentrovanější model teplotní distribuce, který více vylučuje signifikantně odlišná pozorování teplotní mapy.




Obrázek 38: Graf fitness hodnot – nejlepší hodnota fitness: 1,45445 a střední hodnota fitness: 1,82048




Obrázek 39: Graf fitness hodnot – nejlepší hodnota fitness: 1,54123 a střední hodnota fitness: 1,55479




Obrázek 40: Graf fitness hodnot – nejlepší hodnota fitness: 1,14543 a střední hodnota fitness: 1,53675



Obrázek 41: Graf fitness hodnot – nejlepší hodnota fitness: 1,47337 a střední hodnota fitness: 5,20654



Obrázek 42: Graf fitness hodnot – nejlepší hodnota fitness: 0,881234 a střední hodnota fitness: 1,90901



Obrázek 43: Graf fitness hodnot – nejlepší hodnota fitness: 0,637925 a střední hodnota fitness: 0,933263

Na výše uvedených obrázcích jsou uvedeny grafy, kde jsou zobrazeny nejlepší hodnoty fitness a střední hodnoty fitness. Jak si všimneme, nejlepší hodnota je ta, která je co nejmenší naopak střední hodnota je se pohybuje i ve vyšších hodnotách.

Tabulka 10: Výpočetní čas při nastavení počtu shluků 3, velikost populace 50 a generace 80

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	11,76	11,45	10,77
	Čelo	13,91	11,31	10,91
40 ml	Nos	10,59	10,57	10,93
	Čelo	13,38	10,98	11,29
80 ml	Nos	11,34	10,89	11,59
	Čelo	13,79	10,86	11,02
120 ml	Nos	10,95	10,62	10,96
	Čelo	13,61	11	10,68
160 ml	Nos	11,39	10,41	12,34
	Čelo	13,92	11,87	12,85
200 ml	Nos	12,74	9,86	11,07
	Čelo	13,75	10,96	11,39


Jak je zobrazeno v tabulce 10, je evidentní že výpočetní čas pro konkrétní nastavení se pohybuje průměrně kolem 11 s. Na obrázku 44 a obrázku 45 je zřetelně vidět, že při počtu shluků 3, není rozeznatelné kdy se extrahovaná část zahřívá nebo je stále chladná. U obrázku 44 červená barva zaznamenává, jak chladnou, tak i zahřívanou část a u obrázku 45 modrá barva zaznamenává zahřívanou část dané oblasti čela. Níže v tabulce 11 a tabulce 12 jsou zaznamenány výpočetní časy pro další nastavení počtu generací a iterací.

Tabulka 11: Výpočetní čas při nastavení počtu shluků 3, velikost populace 100 a generace 100

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	13,42	12,46	13,29
	Čelo	18,62	39,09	12,70
40 ml	Nos	15,09	14,44	12,33
	Čelo	19,03	13,16	17,13
80 ml	Nos	16,28	15,41	14,63
	Čelo	20,86	13,09	13,62
120 ml	Nos	13,36	15,45	23,35
	Čelo	20,23	15,16	12,15
160 ml	Nos	16,57	13,33	11,82
	Čelo	21,50	12,88	10,69
200 ml	Nos	14,28	13,30	19,57
	Čelo	21,78	16,37	15,59

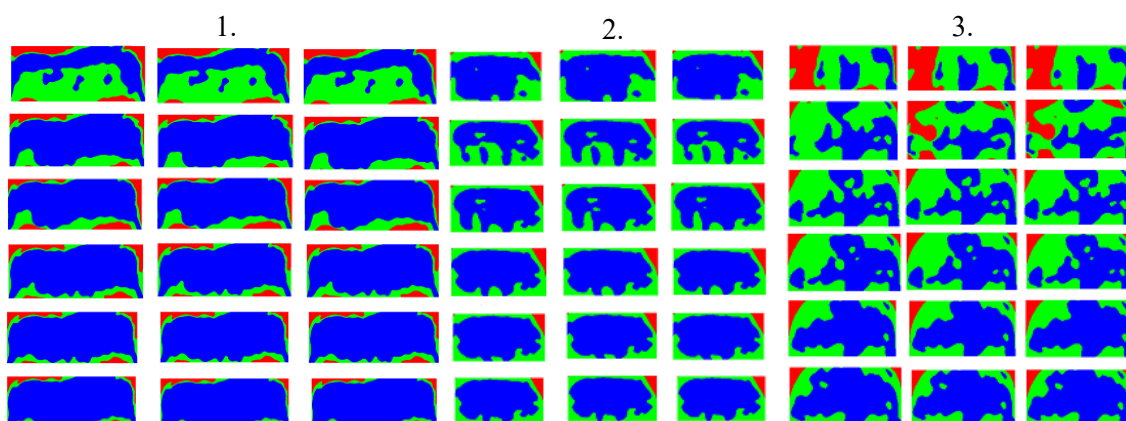
Tabulka 12: Výpočetní čas při nastavení počtu shluků 3, velikost populace 50 a generace 100

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	14,41	12,33	12,63
	Čelo	21,55	11,61	13,34
40 ml	Nos	17,38	13,08	10,57
	Čelo	18,37	12,47	11,50
80 ml	Nos	15,05	12,79	11,73
	Čelo	18,62	12,47	11,51
120 ml	Nos	15,07	11,51	12,27
	Čelo	21,09	11,88	12,39
160 ml	Nos	13,06	11,35	12,84
	Čelo	20,47	13,73	17,54
200 ml	Nos	13,12	10,97	13,50
	Čelo	21,69	13,02	13,06



Obrázek 44: Extrahované oblasti zájmu (nos) po segmentaci K-means řízeným ABC algoritmem při nastavení 3 shluků, velikosti populace 50, 100 a 50, generace 80, 100 a 100

Jak je vidět na obrázku 45 pro nastavení pouze tří shluků, nevidíme žádný rozdíl, kdy se extrahované části zahřívají, nebo která část je ještě chladná. Obrázky jsou vždy seřazeny po sloupcích od doby, kdy byl proband bez intoxikace až po požití 200 ml alkoholu. Každý obrázek je rozdělen na tři části, každá část zaznamenává jednoho probanda.



Obrázek 45: Extrahovány oblasti zájmu (čelo) po segmentaci K-means řízeným ABC algoritmem při nastavení 3 shluků, velikosti populace 50, 100 a 50, generace 80, 100 a 100

Tabulka 13: Hodnoty fitness při nastavení počtu shluků 3, velikost populace 50 a generace 80

Obsah alkoholu	Extrakce zájmu	Nejlepší hodnota fitness	Střední hodnota fitness	Nejlepší hodnota fitness	Střední hodnota fitness	Nejlepší hodnota fitness	Střední hodnota fitness
		Proband 1		Proband 2		Proband 3	
Bez intoxikace	Nos	12,4946	37,3242	2,38553	2,38556	1,45266	1,45268
	Čelo	27,9083	58,1703	4,64652	4,65075	0,615042	0,70896
40 ml	Nos	13,2588	13,2589	2,72906	2,73347	1,64347	4,32964
	Čelo	21,3552	21,3562	3,14858	3,14867	2,36775	2,37711
80 ml	Nos	7,70645	7,70654	2,37811	2,37871	1,48482	1,48482
	Čelo	18	18	3,85823	3,8602	2,85045	2,85142
120 ml	Nos	10,1322	10,2039	2,07917	2,08012	1,63207	1,63929
	Čelo	23,5763	23,5786	3,75417	4,4604	4,59862	4,59864
160 ml	Nos	6,44336	6,44644	1,90527	1,90529	1,71077	1,71207
	Čelo	18,9587	60,5267	4,17456	9,873	4,27976	4,27987
200 ml	Nos	5,67459	5,67629	1,51746	1,51747	1,46213	1,46238
	Čelo	14,9147	19,4928	3,51985	10,937	4,13973	9,84818

V tabulce 13 jsou uvedeny hodnoty fitness a jak vidíme, pohybují se většinou v nízkých číslech, jelikož byly nastaveny pouze tři shluky.

Tabulka 14: Výpočetní čas při nastavení počtu shluků 13, velikost populace 200 a generace 150


Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	71,96	53,60	56,71
	Čelo	161,99	57,54	58,07
40 ml	Nos	75,74	57,89	56,35
	Čelo	154,93	58,90	61,05
80 ml	Nos	77,53	58,18	54,81
	Čelo	159,40	69,87	67,27
120 ml	Nos	68,80	55,95	54,93
	Čelo	184,11	63,86	57,62
160 ml	Nos	75,93	60,85	50,54
	Čelo	175,88	66,32	63,06
200 ml	Nos	72,22	60,89	56,53
	Čelo	169,09	71,61	63,15

Tabulka 15: Výpočetní čas při nastavení počtu shluků 13, velikost populace 100 a generace 100

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	30,98	25,79	22,97
	Čelo	60,72	29,04	24,39
40 ml	Nos	31,24	23,19	23,29
	Čelo	63,45	27,72	25,99
80 ml	Nos	30,15	25,53	24,58
	Čelo	58,21	29,59	25,41
120 ml	Nos	29,41	22,57	24,42
	Čelo	60,58	27,68	24,41
160 ml	Nos	30,19	24,62	23,96
	Čelo	60,41	25,80	26,09
200 ml	Nos	30,65	23,51	22,66
	Čelo	58,15	29,08	28,30


Tabulka 16: Výpočetní čas při nastavení počtu shluků 13, velikost populace 50 a generace 100

Obsah alkoholu	Extrakce zájmu	Uplynulý čas [s]		
		Proband 1	Proband 2	Proband 3
Bez intoxikace	Nos	20,54	16,24	16,67
	Čelo	33,53	17,23	14,88
40 ml	Nos	18,41	14,45	16,40
	Čelo	33,63	18,55	15,94
80 ml	Nos	19,53	14,78	16,34
	Čelo	34,02	16,93	18,39
120 ml	Nos	18,68	15,04	16,67
	Čelo	33,89	18,05	18,48
160 ml	Nos	17,08	14,73	15,93
	Čelo	34,23	16,51	17,51
200 ml	Nos	20,49	16,62	16,91
	Čelo	35,71	16,92	18,54



Obrázek 46: Extrahované části (nos) u tří probandů při nastavených 13-ti shluků, velikost populace 200,100 a 50, generace 150, 100 a 100


Na obrázku 46 jsou extrahované části obličeje, v tomto případě nos, kde v první skupině jsou extrahované části od probanda č. 1, dále od probanda č.2 a naposled od probanda č.3. Obrázky jsou vždy seřazeny po sloupcích od doby, kdy byl proband bez intoxikace až po požití 200 ml alkoholu. V tomto případě bylo použito v programu Matlab nastavení 13-ti shluků a měnil se počet velikost populace a generace (velikost populace 250, 100, 50 a generace 150, 100, 100). Na níže uvedeném obrázku 47 máme zobrazeny extrahované části obličeje (čelo) se stejným nastavením jako u obrázku viz výše.




Obrázek 47: Extrahované části (čelo) u tří probandů při nastavených 13-ti shluků, velikost populace 200,100 a 50, generace 150, 100 a 100

8 Binární model IR teplotní distribuce

Finálním výstupem analýzy je teplotní model, reflektující dynamický proces intoxikace alkoholem. Model je reprezentován příslušnou segmentační třídou oblasti nosu a čela, která vykazuje signifikantní dynamiku v průběhu intoxikace. Ostatní segmentační třídy jsou potlačeny do pozadí v rámci binárního modelu. Poté byl vyobrazen binární model a výpočet plochy dané části. U vyextrahované části (nos) se plocha chladné tkáně zmenšovala naopak u extrahované části čela, se plocha zahřáté tkáně zvětšovala v průběhu intoxikace. Na obrázku 48 je vyobrazen binární model teplotní distribuce nosu a jde vidět, jak se teplotní mapa chladné části zmenšovala. Totéž je zaznamenáno na obrázku 50 a obrázku 52. Naopak na obrázku 49 je vyobrazen binární model čela a zde se teplotní mapa zahřáté části zvětšovala s postupně zvyšujícím se množstvím alkoholu. Pro obrázek 51 a obrázek 53 platí totéž.



Obrázek 48: Binární model teplotní distribuce extrahované části (nos) u prvního probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu

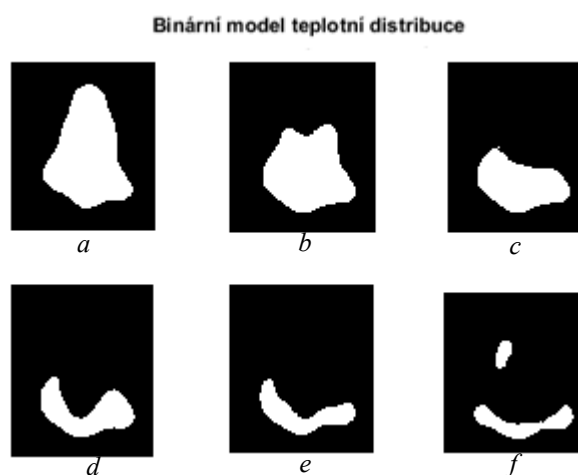


Obrázek 49: Binární model teplotní distribuce extrahované části (čelo) u prvního probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu

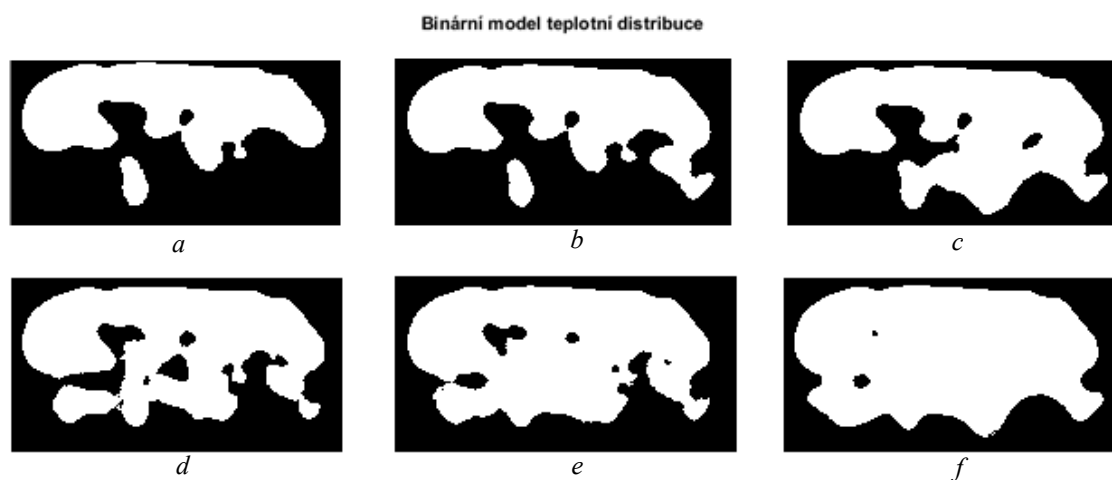
Tabulka 17: Plocha binárního modelu extrahovaných částí u prvního probanda

Obsah alkoholu	Plocha nosu	Plocha čela
Bez intoxikace	14561	31929
40 ml	12698	63289
80 ml	3271	69320
120 ml	3124	79177
160 ml	1135	80372
200 ml	1293	81720

V tabulce 17 jsou uvedeny plochy extrahovaných částí, kdy jde vidět, že plocha nosu se postupně zmenšovala, naopak plocha čela se postupně zvyšovala. Tabulka 18 a tabulka 19 udává taktéž plochy binárního modelu od probanda č.2 a probanda č.3.



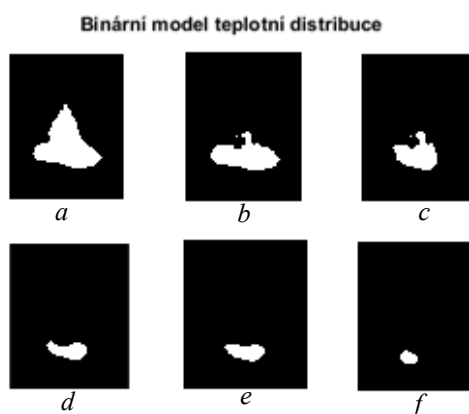
Obrázek 50: Binární model teplotní distribuce extrahované části (nos) u druhého probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu



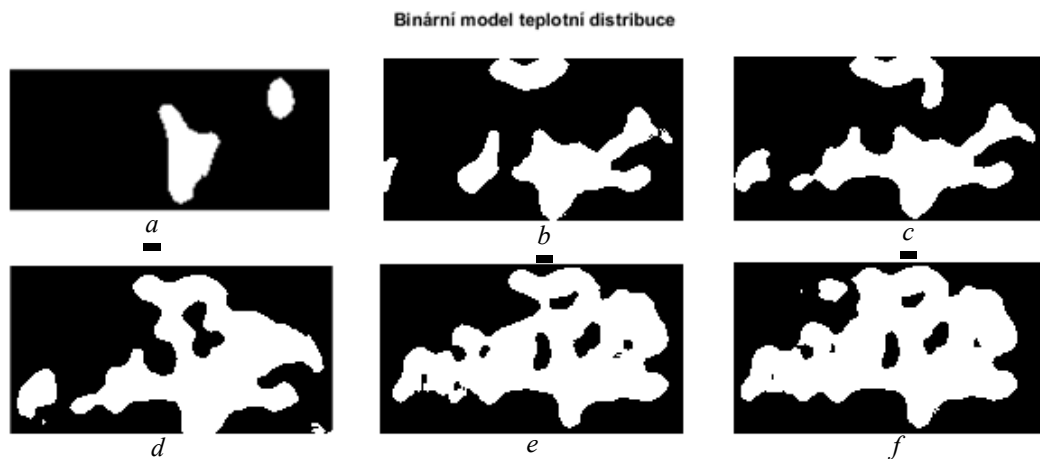
Obrázek 51: Binární model teplotní distribuce extrahované části (čelo) u druhého probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu

Tabulka 18: Plocha binárního modelu extrahovaných částí u druhého probanda

Obsah alkoholu	Plocha nosu	Plocha čela
Bez intoxikace	1738	6483
40 ml	1405	6937
80 ml	992	8574
120 ml	692	8570
160 ml	586	9546
200 ml	443	10776



Obrázek 52: Binární model teplotní distribuce extrahované části (nos) u druhého probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu



Obrázek 53: Binární model teplotní distribuce extrahované části (čelo) u třetího probanda: a) bez intoxikace, b) 40 ml množství alkoholu, c) 80 ml množství alkoholu, d) 120 ml množství alkoholu, e) 160 ml množství alkoholu, f) 200 ml množství alkoholu

Tabulka 19: Plocha binárního modelu extrahovaných částí u třetího probanda

Obsah alkoholu	Plocha nosu	Plocha čela
Bez intoxikace	572	939
40 ml	384	3236
80 ml	259	4154
120 ml	161	5911
160 ml	191	6653
200 ml	108	7390

9 Závěr

Tato práce se zabývá určením a modelováním míry intoxikace alkoholem pomocí aplikování genetických algoritmů, které jsou využívány k optimalizaci K-means shlukování na oblasti čela a nosu, kde je tento problém nejlépe identifikovatelný. Jelikož tyto části obličeje, nejvíce podléhají intoxikaci alkoholem.

V práci byly nejprve rozebrány metody pro určení intoxikaci alkoholem v krvi pomocí IR záznamů a poté různé segmentační metody, které se využívají na medicínská obrazová data. Dále také vysvětlení genetického algoritmu, jak funguje.

Následně byla nahrána datová struktura všech záznamů od 20-ti probandů a poté vybráno pět probandů, u kterých se srovnávali jejich data např. systolický a diastolický tlak, puls jak se měnili na množství požitého alkoholu. Dále zde byli další parametry jako jsou věk, pohlaví, pravidelně užívané léky apod. Z těchto probandů byli poté vybráni další tři probandi, u kterých budou nejlepší výsledky. Následně se nahráli od těchto probandů snímky z IR kamery. Snímky byly postupně seřazeny po požití daného množství alkoholu, (bez intoxikace, 40 ml, 80 ml, 120 ml, 160 ml, 200 ml). Alkohole byl vždy podáván s 30-ti minutovým prodlením.

V další části práce byl originální snímek z IR kamery předzpracován do monochromatického formátu a následně byla provedena dekompozice monochromatického formátu na jednotlivé chrominanci složky R, G, B. Ve výsledku jde vidět, že na R vrstvě není rozeznatelný kontrast, kdy byla daná část obličeje zahřátá po intoxikaci alkoholem nebo ne. Naopak na B vrstvě byl tento kontrast vysoce rozeznatelný. Následně byly z monochromatického formátu extrahované dané oblasti zájmu (nos, čelo).

V neposlední řadě byl navrhnut segmentační algoritmus, který byl K-means řízený ABC algoritmem. Tento algoritmus byl aplikován, na již výše extrahované části obličeje. Zde se muselo určit optimální nastavení, kde teplotní mapa bude nejlépe rozeznatelná. Optimální nastavení činilo K-means – 8 shluků a ABC algoritmus: počet generací – 100 a počet generací (iterací) – 100. V práci je také určen výpočetní čas daného nastavení, jak dlouho algoritmus vykreslil graf nejlepší a střední hodnoty fitness funkce. Následně se nastavení měnilo, buď bylo podhodnoceno nebo naopak nadhodnoceno, kdy ani v jednom případě nebylo možné rozeznat teplotní mapu.

Na závěr byl určen dynamický model teplotní distribuce, který byl dán selekcí příslušné segmentační třídy a současně eliminoval ostatní třídy. A také byla určena plocha dané oblasti zájmu v pixelech, u nosu se plocha snižovala naopak u plochy čela se s postupnou intoxikací zvyšovala.

10 Použitá literatura

- [1] Risham P., Jatinder K., Rakesh K., Int. Journal of Electrical & Electronics Engg. Vol. 2, Spl. Issue 1 (2015) e-ISSN: 1694-2310 | p-ISSN: 1694-2426
- [2] Spectral Emissivity of Skin and Pericardium, J. STEKETEE, Department of Biological and Medical Physics, Erasmus University, Rotterdam, The Netherlands, PHYS. MED. BIOL., 1973, VOL. 18, NO. 5, 686-694. 01973
- [3] Takahashi, K., Hiramatasu, K., Tetsuishi, M. Experiments on detection of drinking from face images using neural networks (2016) Proceedings - 2015 2nd International Conference on Soft Computing and Machine Intelligence, ISCMi 2015, art. no. 7414682, pp. 97-101.
- [4] Ljungblad, J., Hök, B., Allalou, A., Pettersson, H. Passive in-vehicle driver breath alcohol detection using advanced sensor signal acquisition and fusion (2017) Traffic Injury Prevention, 18, pp. S31-S36.
- [5] Navarro, L.A., Diño, M.A., Joson, E., Anacan, R., Cruz, R.D. Design of Alcohol Detection System for Car Users thru Iris Recognition Pattern Using Wavelet Transform (2017) Proceedings - International Conference on Intelligent Systems, Modelling and Simulation, ISMS, art. no. 7877181, pp. 15-19
- [6] Rani, P.S., Subhashree, P., Devi, N.S. Computer vision based gaze tracking for accident prevention (2016) IEEE WCTFTR 2016 - Proceedings of 2016 World Conference on Futuristic Trends in Research and Innovation for Social Welfare, art. no. 7583976.
- [7] Karoly, H.C., Weiland, B.J., Sabbineni, A., Hutchison, K.E. Preliminary functional MRI results from a combined stop-signal alcohol-cue task (2014) Journal of studies on alcohol and drugs, 75 (4), pp. 664-673.
- [8] *Elektrochemické alkoholtestery* [online]. 2014 [cit. 2018-04-12]. Dostupné z: <http://www.alkoholtester.cz/eshop/elektrochemicke/>
- [9] Alcohol tester - DA 7000. *Alkoholtester.cz* [online]. 2014 [cit. 2018-04-12]. Dostupné z: <http://www.alkoholtester.cz/zbozi/made-in-korea/polovodicove/4-alkohol-tester---da-7000/>
- [10] *Eastport.cz* [online]. Praha, 2018 [cit. 2018-04-12]. Dostupné z: <http://www.eastport.cz/spektrofotometr-6850-jenway-bibby-scientific.html>
- [11] Koukiou, G. and Anastassopoulos, V. (2012) 'Drunk person identification using thermal infrared images', Int. J. Electronic Security and Digital Forensics, Vol. 4, No. 4, pp.229–243.
- [12] Koukiou, G., Anastassopoulos, V. Facial blood vessels activity in drunk persons using thermal infrared, 4th International Conference on Imaging for Crime Detection and Prevention, London, UK, November 2011, Kingston University, 1-4.
- [13] Koukiou, G., Anastassopoulos, V. Drunk person screening using eye thermal

- signatures, J. Forensic Sci. 2016; 61(1): 259-264.
- [14] Koukiou, G., Anastassopoulos, V. Neural Networks for identifying drunk persons using thermal infrared imagery, Forensic Science International (2015), <http://dx.doi.org/10.1016/j.forsciint.2015.04.022>
- [15] Zhihua X., Peng J., Ying X. and Ke L." Drunk identification using far infrared imagery based on DCT features in DWT domain ", Proc. SPIE 10157, Infrared Technology and Applications, and Robot Sensing and Advanced Control, 101571F (October 25, 2016); doi:10.1117/12.2246469
- [16] Topic, A., Djukic, M. Diagnostic characteristics and application of alcohol biomarkers (2013) Clinical Laboratory, 59 (3-4), pp. 233-245.
- [17] Kraut, J.A. Diagnosis of toxic alcohols: Limitations of present methods (2015) Clinical Toxicology, 53 (7), pp. 589-595.
- [18] Kuswandi, B., Irmawati, T., Hidayat, M.A., Jayus, Ahmad, M. A simple visual ethanol biosensor based on alcohol oxidase immobilized onto polyaniline film for halal verification of fermented beverage samples (2014) Sensors (Switzerland), 14 (2), pp. 2135-2149.
- [19] He, J., Hu, Y., Pakarinen, S., Li, B., Zhou, Z. Different effects of alcohol on automatic detection of colour, location and time change: A mismatch negativity study (2014) Journal of Psychopharmacology, 28 (12), pp. 1109-1114.
- [20] Pham DL, Prince JL, Dagher AP, Xu C. 1997. An automated technique for statistical characterization of brain tissues in magnetic resonance imaging. *Int. J. Pattern Recognit. Artif. Intell.*
- [21] Ge Y, Fitzpatrick JM, Dawant BM, Bao J, Kessler RM, Margolin R. 1996. Accurate localization of cortical convolutions in MR brain images. *IEEE Trans. Med. Imaging* 15:418
- [22] Rademacher J, Galaburda AM, Kennedy DN, Filipek PA, Caviness VS. 1992. Human cerebral cortex: localization, parcellation and morphometry with magnetic resonance imaging. *J. Cogn. Neurosci.* 4:352
- [23] Sandor S, Leahy R. 1997. Surface-based labeling of cortical anatomy using a deformable atlas. *IEEE Trans. Med. Imaging* 16:41
- [24] Khaneja N, Miller MI, Grenander U. 1998. Dynamic programming generation of curves on brain surfaces. *IEEE Trans. Pattern Anal. Mach. Intell.* 20:1260
- [25] Simmons A, Tofts PS, Barker GJ, Arridge SR. 1994. Sources of intensity nonuniformity in spin echo images at 1.5T. *Magn. Reson. Med.* 32:121
- [26] Sled JG, Pike GB. 1998. Standing-wave and RF penetration artifacts caused by elliptic geometry: an electrodynamic analysis of MRI. *IEEE Trans. Med. Imaging* 17:653
- [27] Rajapakse JC, Giedd JN, Rapoport JL. 1997. Statistical approach to segmentation of single-channel cerebral MR images. *IEEE Trans. Med. Imaging* 16:176

- [28] Pappas TN. 1992. An adaptive clustering algorithm for image segmentation. *IEEE Trans. Signal Process.* 40:901
- [29] Pham DL, Prince JL. 1999. An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Pattern Recognit. Lett.* 20:57
- [30] Wells WM, Grimson WEL, Kikinis R, Jolesz FA. 1996. Adaptive segmentation of MRI data. *IEEE Trans. Med. Imaging* 15:429
- [31] Held K, Kops ER, Krause BJ, Wells WM, Kikinis R, et al. 1997. Markov random field segmentation of brain MR images. *IEEE Trans. Med. Imaging* 16(6):878
- [32] Sahoo PK, Soltani S, Wong AKC. 1988. A survey of thresholding techniques. *Comput. Vis. Graph. Image Proc.*
- [33] Mangin JF, Frouin V, Bloch I, Regis J, Krahe J, Lopez. 1995. From 3D magnetic resonance images to structural representations of the cortex topography using topology preserving deformations. *J. Math. Imaging*
- [34] Udupa JK, Samarasekera S. 1996. Fuzzy connectedness and object definition: theory, algorithms and applications in image segmentation. *Graph. Models Image Process*
- [35] Wells WM, Grimson WEL, Kikinis R, Jolesz FA. 1996. Adaptive segmentation of MRI data. *IEEE Trans. Med. Imaging*
- [36] Zhang YJ. 1996. A survey of evaluation methods for image segmentation. *Pattern Recognit. Lett.*
- [37] Hall LO, Bensaid AM, Clarke LP, Velthuizen RP, Silbiger MS, Bezdek JC. 1992. A comparison of neural network and fuzzy clustering techniques in segmenting magnetic resonance images of the brain. *IEEE Trans. Neural Netw.*
- [38] Davatzikos C, Bryan RN. 1996. Using a deformable surface model to obtain a shape representation of the cortex. *IEEE Trans. Med. Imaging*
- [39] McInerney T, Terzopoulos D. 1997. Medical image segmentation using topologically adaptable surfaces. *Lect. Notes Comput. Sci.*
- [40] Xu C, Pham DL, Prince JL, Etemad ME, Yu D. 1998. Reconstruction of the central layer of the human cerebral cortex from MR images. In *Proc. Int. Conf. Med. Image Comput. Comp. Assist. Interv., 1st, Cambridge, MA*
- [41] Talairach J, Tournoux P. 1988. *Co-Planar Stereotaxic Atlas of the Human Brain. 3-Dimensional Proportional System: An Approach to Cerebral Imaging.* Stuttgart, Ger. Thieme. 122 pp.
- [42] Lancaster JL, Rainey LH, Summerlin JL, Freitas CS, Fox PT, et al. 1997. Automated labeling of the human brain: a preliminary report on the development and evaluation of a forward-transform method. *Hum. Brain Mapp.*

- [43]Rajarethinam NC, Andreasen R, Cizadlo T, Arndt S, Swayze VW, et al. 1996. Automatic atlas-based volume estimation of human brain regions from MR images
- [44]Štunc Pavel. Genetické algoritmy a jejich praktické využití [online]. [cit. 2018-04-12]. Dostupné z: http://nlp.fi.muni.cz/uui/referaty2012/pavel_stunc/referat.pdf

Přílohy

Příloha na CD

I. Zdrojové kódy